



INTRODUÇÃO A PROCESSAMENTO DIGITAL DE IMAGENS

**UMA ABORDAGEM VOLTADA PARA SENSORIAMENTO
REMOTO E FUNCIONALIDADES DO SISTEMA SPRING**

Carlos Antonio Reinaldo Costa



REPÚBLICA FEDERATIVA DO BRASIL

Presidente
Fernando Henrique Cardoso

Ministério da Agricultura e do Abastecimento

Ministro
Arlindo Porto Neto

Empresa Brasileira de Pesquisa Agropecuária - Embrapa

Presidente
Alberto Duque Portugal

Diretores
Elza Angela Battaggia Brito da Cunha
Dante Daniel Giacomelli Scolari
José Roberto Rodrigues Peres

Centro Nacional de Pesquisa Tecnológica em Informática para a Agricultura - CNPTIA

Chefe Geral
Moacir Pedroso Júnior

Chefe Adjunto de Pesquisa e Desenvolvimento
João Camargo Neto

Chefe Adjunto Administrativo
Leila Maria Lenk

EMBRAPA-CNPTIA. Relatório Técnico, 4.

Exemplares desta publicação podem ser solicitados à:
Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA
**Centro Nacional de Pesquisa Tecnológica em Informática
para a Agricultura - CNPTIA**

Av. Dr. André Tosello s/nº.

Cidade Universitária "Zeferino Vaz" - Barão Geraldo

Caixa Postal 6041

13083-970 - Campinas, SP

Telefone: (019) 289-9800

Fax: (019) 289-9594

E-mail: cnptia@cnptia.embrapa.br

URL: <http://www.cnptia.embrapa.br>

Comitê de Publicações: José Ruy Porto de Carvalho
Laurimar Gonçalves Vendrusculo
Luciana Alvim Santos Romani
Marcia Izabel Fugisawa Souza
Mário Antonio do Nascimento (presidente)
Kleber Xavier Sampaio de Souza

Editoração: Ivanilde Dispatto

Tiragem: 80 exemplares

COSTA, C.A.R. *Introdução a processamento digital de imagens:*
uma abordagem voltada para sensoriamento remoto e
funcionalidades do sistema SPRING. Campinas: EMBRAPA-
CNPTIA, 1998. 45p. (EMBRAPA-CNPTIA. Relatório Técnico, 4).

Processamento digital de imagens; Sensoriamento remoto;
Sistema de informações geográficas; Software SPRING; SIG
Digital image processing; Remote sensing; Geographical
information system; GIS.

©Embrapa, 1998

SUMÁRIO

Resumo.....	1
Abstract.....	1
1. Introdução.....	3
1.1. Processamento Digital de Imagens.....	3
1.2. Conteúdo do Trabalho.....	4
2. Conceitos Básicos.....	6
2.1. Imagens Digitais.....	6
2.1.1. Imagens de Sensoriamento Remoto.....	6
2.1.2. Representação de Imagens Digitais.....	9
2.1.3. Outros Tipos de Imagens.....	13
2.2. O SPRING.....	13
2.3. Leituras Complementares.....	14
3. Préprocessamento: Restauração e Registro de Imagens.....	15
3.1. Restauração de Imagens.....	15
3.1.1. Ruídos Causados pelo Sensor.....	15
3.1.2. Ruído Speckle.....	16
3.2. Registro e Transformações Geométricas.....	17
3.2.1. Transformação de Coordenadas.....	17
3.2.2. Interpolação.....	18
3.3. Restauração e Registro de Imagens no SPRING.....	19
4. Realce de Imagens.....	20
4.1. Manipulação de Contraste.....	20
4.1.1. Transformações com Funções Predefinidas.....	22
4.1.2. Equalização de Histograma.....	23
4.2. Filtragem.....	23
4.2.1. Filtros Lineares.....	23
4.2.2. Filtros Não-lineares.....	27
4.2.2.1. Operadores de Gradiente.....	28
4.2.2.2. Filtros Morfológicos.....	28
4.3. Operações entre Bandas.....	29
4.3.1. Operações Aritméticas.....	30
4.3.2. Componentes Principais.....	31
4.4. Coloração.....	31
4.5. Realce de Imagens no SPRING.....	32
4.5.1. Manipulação de Contraste.....	32
4.5.2. Filtragem.....	32
4.5.3. Operações entre Bandas.....	33
4.5.4. Coloração.....	33
5. Análise de Imagens.....	35
5.1. Tipos de Feições em Imagens.....	36
5.1.1. Feições Espaciais.....	36
5.1.2. Bordas e contornos.....	36
5.1.3. Textura.....	36
5.1.4. Forma de Objetos.....	37
5.2. Segmentação de Imagens.....	37
5.3. Classificação de Imagens.....	38
5.3.1. Classificação Supervisionada.....	39
5.3.2. Classificação Não-supervisionada.....	39
5.4. Análise de Imagens com o SPRING.....	40
5.4.1. Segmentação de Imagens no SPRING.....	40

5.4.2. Classificação de imagens no SPRING.....	41
5.4.2.1. Classificação por Pixel.....	41
5.4.2.2. Classificação por Região.....	42
5.4.2.3. Pós-classificação.....	42
6. Referências Bibliográficas.....	44

LISTA DE TABELAS

TABELA 1.1. Distinção entre áreas de estudo que envolve imagens digitais.....	4
TABELA 2.1. Regiões do espectro eletromagnético mais usadas em sensoriamento remoto.....	6
TABELA 2.2. Comparação entre diferentes sistemas sensores.....	9
TABELA 2.3. Resolução de diferentes sistemas sensores.....	11
TABELA 2.4. Principais aplicações de diferentes sistemas sensores.....	12

LISTA DE FIGURAS

FIG. 2.1. Imagem de São José dos Campos nas bandas 3, 4 e 5 do sensor TM/Landsat.....	7
FIG. 4.1. Imagem original e com realce de contraste.....	21
FIG. 4.2. Imagem original, filtro passa-baixa e filtro passa-alta.....	26
FIG. 4.3. Efeitos da operação de abertura.....	29
FIG. 4.4. Efeitos da operação de fechamento.....	29

INTRODUÇÃO A PROCESSAMENTO DIGITAL DE IMAGENS: UMA ABORDAGEM VOLTADA PARA SENSORIAMENTO REMOTO E FUNCIONALIDADES DO SISTEMA SPRING

Carlos Antonio Reinaldo Costa¹

RESUMO - Este trabalho fornece uma visão geral e introdutória sobre as técnicas de processamento digital de imagens, com foco voltado para aplicações de sensoriamento remoto no manejo de recursos naturais. Sua elaboração foi baseada nas ferramentas de processamento digital de imagens disponíveis no SPRING, um sistema de informações geográficas desenvolvido no Instituto Nacional de Pesquisas Espaciais (INPE). Entretanto, também são descritos alguns outros conceitos e técnicas que vão além do escopo deste sistema. Inicialmente, são dados conceitos gerais sobre processamento digital de imagens, juntamente com alguns exemplos de aplicações. Em seguida, o trabalho é organizado de acordo com a seqüência de ações a serem executadas para extração de informações a partir de imagens de sensoriamento remoto. Este processo é dividido em três partes: pré-processamento, realce e análise. As técnicas de pré-processamento referem-se a restauração e registro de imagens. A restauração diz respeito à correção de erros que podem ser causados por falhas no sistema sensor, interferência atmosférica ou curvatura da terra. O registro visa a associação de uma referência geográfica à cena imageada, necessitando, por vezes, de realização de algumas transformações geométricas na imagem. As técnicas de realce são usadas para melhorar a aparência visual da imagem, visando a análise por especialista humano, ou evidenciar algumas feições de interesse na cena, visando a análise por computador. Por fim, o principal objetivo do processamento de imagens de sensoriamento remoto: a análise de imagens; que se refere a algoritmos para extração automática de informações, a partir de dados de sensoriamento remoto, por meio de técnicas de segmentação e classificação.

Palavras chave: processamento digital de imagens, sensoriamento remoto, SPRING, sistema de informações geográficas.

INTRODUCTION TO DIGITAL IMAGE PROCESSING: AN APPROACH DIRECTED TO REMOTE SENSING AND SPRING GIS TOOLS

ABSTRACT - This work presents an introductory survey on digital image processing techniques, focusing on remotely sensed data for earth resources management applications. Its elaboration was based on digital image processing tools available in software SPRING, a geographical information system developed by National Institute for Spatial Research (INPE). However, some other concepts and techniques, that go over the scope of that

¹ Mestre em Ciência da Computação, Embrapa-CNPTIA atualmente na Embrapa-CNPAT, Rua Dra. Sara Mesquita, 2270 - Bairro Planalto Pici - 60511-110 Fortaleza, CE.

software, are also covered. Initially, general concepts on digital image processing and remote sensing are presented together with some examples applications. Following that, the work is organized according to the sequence of actions to be done for information extraction of remotely sensed images. This process is divided in three parts: preprocessing, enhancement and analysis. Preprocessing technics refers to image restoration and registration. Image restoration involves the correction of errors that may be caused by failures in the sensor system, atmospheric interference or earth curvature. The registration process intends to give a geographical reference to the imaged scene, demanding, sometimes, some geometrical transformations on the image. Enhancement technics are used to improve the visual appearance of an image, for human analysis, or to evidence some interest features on the scene for machine analysis. Finally, the main objective of remotely sensed image processing, the image analysis, refers to algorithms for automatic extraction of information in remotely sensed data by means of segmentation and classification technics.

Key words: digital image processing, remote sensing, SPRING, geographical information system.

INTRODUÇÃO A PROCESSAMENTO DIGITAL DE IMAGENS: UMA ABORDAGEM VOLTADA PARA SENSORIAMENTO REMOTO E FUNCIONALIDADES DO SISTEMA SPRING

1. INTRODUÇÃO

Imagens de sensoriamento remoto representam, na atualidade, uma importante fonte de informações para estudos relacionados a áreas como meteorologia, levantamento de recursos naturais e monitoramento ambiental. Já em meados do século passado, balões equipados com câmaras fotográficas eram utilizados para colher imagens aéreas do solo. Atualmente, uma grande variedade de meios é utilizada para se obter imagens da terra, que vão desde câmaras fotográficas aerotransportadas, até sensores digitais a bordo de satélites em órbita a centenas de quilômetros da superfície. Neste contexto, as técnicas de processamento digital de imagens surgem como ferramenta fundamental para análise e extração dos mais variados tipos de informação a partir de cenas da superfície da terra.

1.1. PROCESSAMENTO DIGITAL DE IMAGENS

O termo *processamento digital de imagens* refere-se à análise e a manipulação de imagens por computador. Este processamento tem basicamente duas finalidades: extração de informação da imagem ou transformação da mesma para melhorar seu aspecto ou facilitar sua análise.

O processamento digital de imagens possui uma vasta gama de aplicações. Ao longo deste trabalho, falamos sobre algumas aplicações de imagens de sensoriamento remoto e nos itens a seguir, citamos outras aplicações que estão entre as mais comuns:

- **Aplicações médicas e biológicas:** detecção de tumores e microorganismos; medida de forma e tamanho de órgãos internos; identificação de tecidos vegetais e animais; classificação e contagem de células; análise de cromossomos, entre outras.
- **Transmissão e armazenamento de imagens:** técnicas avançadas de compressão são usadas na armazenagem de grandes bibliotecas de imagens e na transmissão de cenas estáticas ou em movimento em sistemas de multimídia.
- **Imagens de radar e sonar:** usadas para detecção e reconhecimento de vários tipos de alvos, bem como para orientação de tráfego aéreo e direcionamento em sistemas de mísseis.
- **Astronomia e cosmologia:** imagens provenientes de telescópios e radiotelescópios podem ser processadas para identificação de tamanho, distância ou composição química de corpos celestes.

Além destas aplicações, existem muitas outras que envolvem processamento digital de imagens e também áreas afins, como computação gráfica e reconhecimento de padrões. Um exemplo típico de combinação entre processamento de imagens e

computação gráfica está na elaboração dos efeitos especiais de cinema, nos quais objetos virtuais criados em computador são combinados de maneira quase perfeita com cenas do mundo real. Sistemas de visão computacional, muito usados em robótica e automação industrial, constituem também um exemplo típico de combinação entre processamento de imagens e reconhecimento de padrões.

As fronteiras entre estas áreas de conhecimento não são muito bem definidas, entretanto, podemos fazer uma distinção entre os diferentes conceitos descrevendo as aplicações em termos de entrada e saída. A Tabela 1.1 mostra esta distinção.

TABELA 1.1. Distinção entre áreas de estudo que envolvem imagens digitais (Gomes & Velho, 1994).

	ENTRADA	SAÍDA
Computação gráfica	Dados	imagens
Processamento de imagens	Imagens	imagens
Reconhecimento de padrões	Imagens	dados

Em outras palavras, podemos dizer que computação gráfica é a *síntese*, processamento de imagens é a *transformação* e reconhecimento de padrões é a *interpretação* de imagens². Neste trabalho, obviamente a atenção é voltada principalmente para transformações de imagens, entretanto, também falamos brevemente sobre interpretação, quando descrevemos técnicas relacionadas a segmentação e classificação.

1.2. CONTEÚDO DO TRABALHO

Neste trabalho, procuramos dar uma visão geral sobre como as técnicas de processamento digital de imagens (PDI) podem ser utilizadas para a extração de diversos tipos de informação a partir de imagens de sensoriamento remoto. Serão introduzidos alguns conceitos básicos, mostrando como eles podem ser utilizados para se atingir os objetivos esperados e dando maior ênfase às funcionalidades disponíveis no Sistema de Processamento de Informações Georreferenciadas (SPRING, 1996).

No Capítulo 2, são dados alguns conceitos básicos relacionados com processamento digital de imagens e exemplos de aplicações envolvendo imagens digitais. Nos três capítulos seguintes, são divididas as principais atividades realizadas para se extrair informações de imagens de sensoriamento remoto. O Capítulo 3 refere-se a técnicas de restauração, utilizadas para corrigir alguns tipos de distorções nas imagens, e registro, um dos primeiros passos para a extração informações referenciadas geograficamente na imagem. No Capítulo 4, são descritas algumas técnicas de realce de imagens, que são importantes para se melhorar o aspecto visual das imagens ou destacar elementos de interesse. Por fim, no Capítulo 5, são descritas

² O termo *reconhecimento de padrões* é usado também em aplicações não pictóricas, como análise de sinais de eletrocardiogramas e eletroencefalogramas, reconhecimento de voz, sismologia, entre outros.

algumas técnicas de análise de imagens, incluindo a classificação, um dos principais objetivos do processamento de imagens de sensoriamento remoto.

As funcionalidades de processamento de imagens do sistema SPRING foram utilizadas como referência neste trabalho, entretanto, o mesmo não é dirigido apenas a usuários deste sistema, mas também a qualquer pesquisador ou profissional interessado em lidar com processamento de imagens de sensoriamento remoto.

Não estamos supondo nenhum conhecimento anterior, por parte do leitor, quanto a processamento digital de imagens ou outras áreas da ciência da computação. No decorrer do texto, tentamos nos abster ao máximo do uso de fórmulas matemáticas. Entretanto, em alguns casos não pudemos deixar de usá-las. O leitor que não tiver muita familiaridade com tais expressões, poderá simplesmente saltá-las, sem grandes prejuízos para a compreensão do trabalho. Por outro lado, estas expressões poderão ser úteis para o leitor que deseje ter uma melhor noção a respeito do mecanismo de funcionamento do algoritmos.

2. CONCEITOS BÁSICOS

2.1. IMAGENS DIGITAIS

Imagens digitais são constituídas por conjuntos discretos de elementos pictóricos denominados *pixels* (termo originado do inglês *picture elements*), que se distribuem ao longo de uma grade regular. Estas imagens são, geralmente, representadas por uma matriz ou por uma função bidimensional discreta e não negativa, que assume valores não nulos apenas em um conjunto finito de pontos. Para cada pixel é associado um valor numérico que indica um nível de luminosidade ou reflectância média de uma região relativamente pequena de uma cena. Estes valores são representados graficamente por *níveis de cinza* que podem variar do preto até o branco. Valores mais altos são representados por níveis de cinza mais claros e valores mais baixos por níveis de cinza mais escuros. Quanto menor for a área representada por cada pixel, maior será a quantidade de detalhes preservados na representação digital.

2.1.1. Imagens de Sensoriamento Remoto

Em imagens de sensoriamento remoto, os pixels representam regiões da superfície da terra. Frequentemente, estas imagens são *multiespectrais*, isto é, a mesma cena é representada em várias *bandas espectrais* geradas simultaneamente, cada uma delas resultante de uma determinada faixa do espectro eletromagnético. A Tabela 2.1 mostra exemplos de faixas do espectro eletromagnético de maior interesse para aplicações de sensoriamento remoto. As faixas entre o azul e o infravermelho médio são refletivas, ou seja, a energia registrada corresponde à luz do sol refletida pelo terreno; por outro lado, a faixa do infravermelho distante é emissiva (ou termal), o que significa que a energia registrada é emitida pelo próprio objeto imageado, devido ao seu calor. Na faixa das microondas, normalmente o que se registra é o retorno a partir de um pulso de energia emitido pelo próprio sensor. A Figura 2.1 mostra um exemplo de imagem multiespectral. Neste exemplo, são mostradas três bandas geradas pelo sensor TM do satélite Landsat. A banda 3 (B3), que está na faixa do vermelho da luz visível, a banda 4 (B4), que está na faixa do infravermelho próximo, e a banda 5 (B5), que está na faixa do infravermelho médio. Pode-se observar que as feições do terreno possuem respostas distintas em comprimentos de onda diferentes. A vegetação, por exemplo, aparece mais clara na banda 4, enquanto que as áreas urbanas, apresentam maior definição na banda 3.

TABELA 2.1. Regiões do espectro eletromagnético mais usadas em sensoriamento remoto (Lillesand & Kiefer, 1994).

Faixa do espectro		Comprimento de onda
Luz visível	Azul	0,4 - 0,5 μm
	Verde	0,5 - 0,6 μm
	Vermelho	0,6 - 0,7 μm
Infravermelho	Próximo	0,7 - 1,3 μm
	Médio	1,3 - 3,0 μm
	Distante	3,0 - 15,0 μm
Microondas		1mm - 1m




FIGURA 2.1. Imagem de São José dos Campos nas bandas 3, 4 e 5 do sensor TM/Landsat.

As diferenças de intensidade de resposta, que ocorrem entre diferentes bandas, caracterizam o padrão de resposta espectral, também chamado, frequentemente, de *assinatura espectral*. Este padrão pode não ser único para cada feição do terreno, mas, mesmo assim, é de grande utilidade na determinação de diferentes classes de uso de solo ou mapeamento de recursos naturais.

Os sistemas sensores, usados na detecção de imagens de sensoriamento remoto, podem ser classificados em três tipos: sistemas fotográficos, sensores de varredura eletro-ótica e sensores de microondas.

No primeiro caso, as imagens são obtidas por meio de câmaras fotográficas instaladas a bordo de aeronaves que sobrevoam a área a ser imageada. Existem, basicamente, três tipos de câmaras (Novo, 1995): as câmaras métricas caracterizam-se pelo alto grau de correção geométrica e são geralmente utilizadas para fins cartográficos; as câmaras de reconhecimento garantem maior fidelidade do registro das características radiométricas da superfície, resultando assim, em uma maior distinção entre os objetos da cena; e as câmaras multiespectrais, registram a cena em filmes preto e branco, mas com a radiação decomposta em diferentes faixas espectrais, através da utilização de filtros.

Quanto aos filmes, também podem ser classificados em três tipos (Lillesand & Kiefer, 1994): o filme preto e branco pancromático é o mais utilizado em fotografia aérea e registra radiação que pode ir do ultravioleta a luz visível; o filme preto e branco infravermelho é capaz de registrar radiação tanto de luz visível quanto do infravermelho próximo; e o filme colorido que, apesar de não ser recomendado para geração de imagens multiespectrais, tem uma vantagem devido ao fato do olho humano ser mais sensível a cores do que a tons de cinza.

Nos sensores de varredura eletro-ótica (Novo, 1995; Lillesand & Kiefer, 1994), as imagens são registradas em forma de sinais elétricos, o que permite sua transmissão a distância. Os pixels, neste caso, são obtidos medindo-se a intensidade da radiação que atinge o sensor quando este aponta em uma determinada direção. O tamanho da área representada por um pixel é determinado por características do sensor, tais como sua altitude e o ângulo de abertura do *campo instantâneo de visada*³. As imagens são construídas movendo-se o sensor ao longo do *campo de visada*⁴, e colhendo-se sucessivas amostras da superfície através de medições da radiação recebida. Como no caso dos sistemas fotográficos, estes sensores são *passivos*, ou seja, registram apenas a radiação que é emitida ou refletida pelos objetos da cena.

Entre os sensores que operam na faixa de microondas, os mais largamente utilizados são os chamados *radares de visada lateral*⁵ (Novo, 1995; Lillesand & Kiefer, 1994). Estes sensores, ao contrário dos anteriores, são *ativos*: uma antena transmissora emite pulsos de microondas, em intervalos de tempo regulares, e uma antena receptora mede a intensidade da energia retornada após incidirem com objetos da cena imageada.

A escolha de um sistema sensor para a execução de uma missão de sensoriamento remoto deve levar em conta uma série de características inerentes a eles, as quais podem ser consideradas vantagens ou desvantagens, dependendo dos objetivos a

³ Área delimitada para coleta de cada uma das amostras. Em inglês: *instantaneous field of view (IFOV)*.

⁴ Área total representada pela imagem. Em inglês: *field of view (FOV)*.

⁵ Em inglês *side-looking radar (SLR)*.

serem atingidos. A Tabela 2.2 mostra uma comparação, de caráter geral, entre diferentes sistemas sensores.

TABELA 2.2. Comparação entre diferentes sistemas sensores (Novo, 1995).

Sistema sensor	Vantagens	Desvantagens
Fotográfico	<ul style="list-style-type: none"> • alta resolução geométrica; • boa orientação espacial, requerendo, portanto, pouco esforço de correção geométrica; • fáceis de processar e interpretar 	<ul style="list-style-type: none"> • impossibilidade de transmissão a distância; • filmes disponíveis atuam apenas na região do espectro, entre o ultravioleta e o infravermelho próximo; • requerem boas condições de iluminação e são muito suscetíveis a interferência atmosférica.
Eletro-ótico	<ul style="list-style-type: none"> • possibilidade de transmissão a distância; • facilidade de digitalização e análise computacional; • atuam em uma faixa mais ampla do espectro ótico. 	<ul style="list-style-type: none"> • operação mais complexa; • suscetíveis a interferência atmosférica
Radar	<ul style="list-style-type: none"> • possibilidade de transmissão a distância; • podem operar no escuro e em condições meteorológicas adversas 	<ul style="list-style-type: none"> • requerem alto grau de processamento de sinal. • Sujeito a distorções geométricas devido a inclinações do terreno

2.1.2. Representação de Imagens Digitais

Como é necessário que se tenha um número finito de bits para representar imagens em computador, a luminância, que é contínua no mundo real, deve ser quantizada em um número finito de níveis de cinza. Usando-se 6 bits por pixel (64 níveis), já é possível obter uma sensação visual de continuidade dos níveis de cinza. Entretanto, para algumas aplicações é desejável que se tenha uma quantidade maior de níveis de cinza, por isto, alguns sensores são capazes de gerar imagens com até 8 bits por pixel (256 níveis) ou mais.

Cada sistema sensor possui características distintas quanto à resolução, a qual pode ser classificada em espacial, espectral, radiométrica e temporal.

A *resolução espacial* refere-se ao tamanho da área representada por cada pixel da imagem. Por exemplo, uma resolução de 30 metros implica que cada pixel representa a luminância média proveniente de um retângulo de, aproximadamente, 30x30 metros da superfície e que, portanto, objetos distanciados entre si a menos de 30 metros não serão discriminados pelo sistema.

A *resolução espectral* refere-se ao número bandas espectrais no qual é dividida a cena imageada e à variação de frequência que pode ocorrer dentro de cada uma destas bandas. Por exemplo, a resolução espectral do sensor TM do satélite Landsat é de 7 bandas, o que significa que a radiação eletromagnética, proveniente da superfície, é dividida em 7 faixas de frequência diferentes e, para cada uma delas, são geradas, simultaneamente, imagens monocromáticas distintas. Quanto maior for o número de bandas, maiores serão as possibilidades de distinção entre diferentes classes de temáticas na cena.

A *resolução radiométrica* está associada à sensibilidade do sistema sensor para distinguir os níveis de intensidade do sinal captado, e diz respeito ao número de níveis de cinza usados para representar cada banda espectral. Portanto, é a partir da resolução radiométrica que se obtém a quantidade de bits por pixel para a representação das imagens. As bandas dos sensor TM/Landsat, por exemplo, são geradas com 256 níveis de cinza, ou seja, 8 bits por pixel.

Em alguns casos, as imagens são adquiridas em intervalos de tempo fixos, o que contribui para a análise do caráter dinâmico do objeto em estudo. Nestes casos, o intervalo de aquisição de dados expressa a *resolução temporal* do sistema.

A Tabela 2.3 apresenta as características de resolução de alguns sistemas sensores: *Thematic Mapper* (TM) do satélite Landsat, *Haute Resolution Visible* (HRV) do satélite SPOT, *Advanced Very High Resolution Radiometer* (AVHRR) do satélite NOAA, *Along Track Scanning Radiometer* (ATSR) e *Synthetic Aperture Radar* (SAR) do satélite ERS-1, RADARSAT e alguns filmes utilizados em fotografia aérea. No caso dos sensores multiespectrais, as bandas são representadas por letras ou números, e estão posicionadas na Tabela de acordo com as faixas espectrais em que estão contidas (az = azul; vd = verde; vm = vermelho; ivp = infravermelho próximo; ivm = infravermelho médio; ivd = infravermelho distante; mo = microondas). Para os demais sensores, são representadas, na Tabela, as variações de comprimento de onda (em μm) que abrangem.

TABELA 2.3. Resolução de diferentes sistemas sensores (Jensen, 1996).

Sensor	Resolução espectral * (bandas)							Resolução espacial	Resolução temporal
	az	Vd	vm	ivp	ivm	ivd	mo		
Landsat TM	1	2	3	4	5;7	6		30 m	16 dias
SPOT HRV Multiespectral Pancromático		1	2	3				20 m	26 dias
		0,5-----0,7						10 m	26 dias
NOAA AVHRR			1	2	3	4;5		1100 m	14.5/dia
ERS-1 ATSR					1;2	3;4		1000 m	variável
ERS-1 SAR Banda C (5,3 GHz)							C	30 m	variável
RADARSAT Banda C (5,3 GHz)							C	variável	1-6 dias
Filmes fotográficos Pancromático Colorido Infravermelho		0,5-----0,7						variável	variável
	0,4-----0,7								
		0,5-----0,9							

As diferentes bandas espectrais dos sensores têm aplicações distintas em estudos da superfície da Terra. A Tabela 2.4 pode ser útil para orientar em uma primeira escolha de sensores e bandas a serem utilizados em uma missão de sensoriamento remoto. Entretanto, dependendo da complexidade da aplicação, pode ser necessário um estudo mais detalhado, a respeito de interpretação de imagens de diferentes sistemas sensores, como o desenvolvido por Lillesand & Kiefer (1994).

TABELA 2.4. Principais aplicações de diferentes sistemas sensores (Novo, 1995; Jensen, 1996).

Sensor/Banda	Faixa espectral (μm)	Principais aplicações
TM/1	0,45-0,52	Mapeamento de águas costeiras; diferenciação entre solo e vegetação; diferenciação entre vegetação conífera e decídua.
TM/2	0,52-0,60	Reflectância de vegetação verde sadia.
TM/3	0,63-0,69	Absorção de clorofila; diferenciação de espécies vegetais.
TM/4	0,76-0,90	Levantamento de biomassa; delineamento de corpos d'água.
TM/5	1,55-1,75	Medidas de umidade da vegetação; diferenciação entre nuvens e neve.
TM/6	10,40-12,50	Mapeamento de estresse térmico em plantas e outros mapeamentos térmicos.
TM/7	2,08-2,35	Mapeamento hidrotermal.
HRV/1	0,50-0,59	Reflectância de vegetação verde sadia.
HRV/2	0,61-0,68	Absorção de clorofila; diferenciação de espécies vegetais; diferenciação de solo e vegetação.
HRV/3	0,79-0,89	Levantamento de fitomassa; delineamento de corpos d'água.
HRV/pan	0,51-0,73	Estudo de áreas urbanas.
AVHRR/1	0,58-0,68	Mapeamento diurno de nuvem, gelo e neve; definição de feições de solo e cobertura vegetal.
AVHRR/2	0,72-1,10	Delineamento de superfície de água; definição de condições de neve e gelo; avaliação da vegetação e monitoramento meteorológico (nuvens).
AVHRR/ 3 4 5	3,55-3,93 10,30-11,30 11,50-12,50	Mapeamento noturno e diurno de nuvens; análise de temperatura da superfície do mar, lagos e rios; detecção de pontos de alta temperatura (incêndios); umidade do solo.
SAR/ X C S P	2,4 - 3,8 cm 3,8 - 7,5 cm 7,5 - 15 cm 75 - 133 cm	Rugosidade da superfície; umidade do solo; diferenciação entre biomassa verde e morta; topografia. Microondas podem ser úteis também na detecção de características do solo abaixo da vegetação ou do subsolo, devido à sua capacidade de penetração, que é tão maior quanto maior for o comprimento de onda.

2.1.3. Outros Tipos de Imagens

Quando tratamos individualmente cada uma das bandas de uma imagem multiespectral, temos o que é normalmente chamado *imagem em níveis de cinza*. O uso deste tipo de imagem não se restringe ao sensoriamento remoto. Este modelo é usado também em várias outras aplicações, como digitalização de fotografias e sinais de vídeos ou imagens obtidas por mecanismos, tais como raio X, tomografias, radiologia, ressonância magnética, sonar, etc. O número de tons de cinza usados em tais imagens varia de acordo com a aplicação. Em geral utiliza-se 256 tons, o que equivale a 8 bits/pixel. No entanto, existem aplicações que podem exigir uma quantidade maior de tons de cinza, como é freqüente, por exemplo, em imagens médicas.

Apesar da definição de imagem em tons de cinza ser bastante abrangente, ela não é suficiente para representar todos os tipos de imagens digitais. Existem outras categorias de imagens que não podem ser representadas, de maneira satisfatória, apenas por este modelo. Entretanto, a definição de imagem em tons de cinza pode ser facilmente generalizada para se obter a definição de outros tipos de imagem. No caso de *imagens coloridas*, por exemplo, a diferença é que, ao invés de um único número para cada pixel, existirão três, que irão representar os níveis das cores primárias aditivas vermelho, verde e azul ou, alternativamente, os níveis de intensidade, cor e saturação.

Quanto à representação, as imagens que descrevemos acima podem ser classificadas como *imagens de varredura*⁶. Além deste modelo, existe também uma outra abordagem, bastante diferente, para representação de imagens em computador, com a qual se obtém as chamadas *imagens vetoriais*. Neste tipo de imagem, os objetos da cena são descritos em termos de suas bordas e, ao invés de matrizes, são utilizadas linhas poligonais para representá-los. A vantagem mais evidentes deste tipo de abordagem é a economia de espaço em memória e a facilidade de se associar uma topologia aos objetos da cena; entretanto imagens vetoriais dificilmente atingem a grande precisão de detalhes provida por imagens de varredura. Ambos os modelos são de grande utilidade para um infindável número de aplicações, entretanto, aqui nos concentraremos apenas nos problemas e aplicações referentes a imagens de varredura, mesmo porque, problemas de geração e manipulação de imagens vetoriais estão mais próximos do domínio da computação gráfica.

2.2. O SPRING

O SPRING (Sistema de Processamento de Informações Georreferenciadas) (SPRING, 1996) é um sistema para geoprocessamento desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), em cooperação com a Embrapa-CNPTIA. É voltado para aplicações ambientais e cadastrais, permitindo adquirir, armazenar, combinar, analisar e recuperar informações codificadas espacial ou não-espacialmente. Para isto são combinadas funções de processamento de imagens, análise espacial,

⁶ Em inglês *raster images*

modelagem numérica de terreno e consulta a banco de dados espaciais em um único ambiente iterativo.

O sistema é dividido em três módulos: o módulo principal (que leva o nome SPRING), o qual possui as ferramentas de análise espacial e processamento de imagens; o SCARTA, dedicado a confecção de cartas geográficas; e o IMPIMA, que tem as funções de leitura de fitas e CDROMs com imagens de satélite fornecidas pelo INPE.

Este sistema traz a implementação de uma boa variedade de algoritmos para processamento digital de imagens. As ferramentas ali presentes são de muita utilidade para uma grande variedade de aplicações ambientais. Nos capítulos a seguir, nós procuraremos mostrar como o SPRING pode ser utilizado para extrair diferentes tipos de informações de imagens de sensoriamento remoto. Entretanto, a nossa intenção não foi escrever um manual de utilização do sistema, mas sim, introduzir informações conceituais sobre técnicas de processamento digital de imagens, mostrando como elas se aplicam a imagens de sensoriamento remoto, com o uso do sistema SPRING.

2.3. LEITURAS COMPLEMENTARES

As informações a respeito de sensoriamento remoto contidas neste pequeno resumo foram extraídas, principalmente, de três fontes: (Lillesand & Kiefer, 1994), (Novo, 1995) e (Jensen, 1996). O primeira é uma das principais referências para estudantes e pesquisadores de áreas relacionadas a sensoriamento remoto. A segunda é uma das poucas referências em português sobre este assunto. Não é tão completa quanto a primeira, mas traz um bom panorama a respeito do tema. A terceira trata sobre processamento digital de imagens, com o foco voltado para imagens de sensoriamento remoto por satélite ou fotografia aérea, tendo em vista, principalmente, o gerenciamento de recursos naturais. Com relação a conceitos e técnicas de processamento digital de imagens em caráter geral, inúmeras referências podem ser encontradas na literatura. Entre as mais completas citamos: (Jain, 1989), (Pratt, 1991) e (Gonzalez & Woods, 1992). Quanto ao sistema SPRING, uma série de informações podem ser obtidas em sua *homepage* na Internet (SPRING, 1996), inclusive os manuais do usuário.

3. PREPROCESSAMENTO: RESTAURAÇÃO E REGISTRO DE IMAGENS

No capítulo anterior vimos que existe uma grande variedade de meios para aquisição de imagens de sensoriamento remoto. Entretanto, para qualquer sistema sensor, seja ele orbital ou aerotransportado, sempre irão ocorrer falhas na imagem adquirida. Estas falhas podem ser de natureza radiométrica, quando afetam apenas os níveis de cinza da imagem, ou geométricas, quando há distorção no formato dos objetos da cena. Neste capítulo, falamos sobre técnicas utilizadas para corrigir algumas destas distorções. Na seção 3.1 são descritas algumas transformações radiométricas que podem ser utilizadas na restauração de imagens, e na seção 3.2 falamos sobre técnicas de registro e correção geométrica, que são importantes para que se possa extrair informações geograficamente referenciadas de imagens de sensoriamento remoto.

3.1. RESTAURAÇÃO DE IMAGENS

Como dissemos anteriormente, o nível de cinza de cada pixel da imagem deve representar um valor médio da radiação recebida a partir de uma determinada região do solo. Entretanto, na prática nem sempre é isto que acontece. Podem ocorrer erros, que são causados, entre outras coisas, por falhas do sensor, interferência da atmosfera ou pelas próprias características da radiação eletromagnética. Estes erros são chamados, em geral, de *ruídos*.

3.1.1. Ruídos causados pelo sensor

Falhas em detectores podem causar, por exemplo, a ocorrência de linhas onde todos os pixels têm valor zero (preto). Este efeito é conhecido como *line drop-out* (Jensen, 1996) e, neste caso, não é possível corrigir o erro totalmente, uma vez que valores reais dos pixels foram totalmente perdidos. Entretanto, o problema pode ser bastante amenizado fazendo-se uma estimativa dos valores dos pixels perdidos, baseando-se em suas vizinhanças. Para determinar as linhas nas quais o ruído ocorreu, compara-se a média dos níveis de cinza da linha com um determinado limiar; se a média estiver abaixo do limiar, os pixels da linha são considerados ruídos, e seus valores podem ser estimados pela média aritmética entre os níveis de cinza dos pixels inferior e superior, ou seja, dado um pixel $p(i,j)$ no qual ocorre ruído, seu valor será substituído por:

$$p(i,j) = \frac{p(i,j-1) + p(i,j+1)}{2}$$

Em alguns sistemas orbitais, como é o caso do Landsat/TM, podem, também, ocorrer erros devido a diferenças de ajuste entre os detectores, causando um efeito de listras na imagem. Estes e outros erros, que são inerentes e específicos de cada sistema sensor, podem ter suas características bem conhecidas, de modo que seus efeitos podem ser bastante minimizados por meio de filtros lineares (veja Seção 4.2.1), cujas máscaras tenham sido elaboradas com base nestas características.

3.1.2. Ruído Speckle

Quando uma radiação eletromagnética é dispersa a partir de uma superfície cuja rugosidade é da ordem do comprimento de onda, podem ocorrer interferências, construtivas e destrutivas, que causam um tipo de ruído conhecido como *speckle*, o qual produz, na imagem, uma textura semelhante a uma mistura de sal e pimenta. Este tipo de ruído é muito comum em sensores que operam na faixa de microondas, como é o caso dos radares, e reduzem a resolução espacial da imagem, dificultando a identificação das diferentes feições do terreno.

Uma maneira de minimizar os efeitos do *speckle* é por meio do processamento em *multi-visadas* (*multi-look*). Neste procedimento, são geradas várias imagens independentes da mesma área a partir de diferentes porções da abertura sintética do sistema. Como o ruído presente em cada uma das imagens são estatisticamente independentes, tomando-se a média dos níveis de cinza dos pixels de mesma posição em visadas (*looks*) diferentes, será obtida uma suavização da imagem. A quantidade de *speckle* existente na imagem resultante, será inversamente proporcional a raiz quadrada do número de visadas (Jain, 1989).

Uma outra maneira de se obter a redução do *speckle*, é através de filtragem (veja Seção 4.2). O filtro mais simples que pode ser utilizado com este objetivo é o filtro de média, no qual o nível de cinza de cada pixel é substituído pela média aritmética dos níveis de cinza de uma janela de $N \times N$ pixels centrada na posição corrente. Este filtro tem a desvantagem de degradar as bordas da imagem, produzindo um efeito de borramento.

Um outro filtro, também bastante simples, que é capaz de reduzir o ruído com uma menor degradação das bordas é filtro de mediana. Neste filtro, para cada pixel, é tomada uma janela de $N \times N$ pixels, com centro na posição corrente. Os níveis de cinza desta janela são ordenados e o valor do pixel central é substituído pela mediana destes valores.

Estes dois filtros são de caráter geral, não foram desenvolvidos especificamente para remoção de ruído *speckle*. Porém, existem filtros que foram desenvolvidos para este fim e com os quais se pode obter melhores resultados. Alguns exemplos são o filtro de Lee (Lee, 1981), o filtro de Frost (Frost *et al.*, 1982) e o filtro de Kuan (Kuan *et al.*, 1982). Estes filtros são adaptativos, ou seja, a transformação a ser feita é baseada em uma análise estatística local que leva em conta a heterogeneidade da cena, de tal forma que o ruído possa ser minimizado, preservando-se a informação radiométrica e textural.

Muitos dos filtros de restauração de imagens são baseados nas características radiométricas do tipo de ruído a ser eliminado. Portanto, recomenda-se que o processo de filtragem seja feito sobre as imagens originais, antes que seja feita qualquer transformação geométrica ou operação de realce, pois estes procedimentos podem alterar as características radiométricas da imagem e do ruído presente nelas, de modo que os filtros podem não obter o resultado esperado.

3.2. REGISTRO E TRANSFORMAÇÕES GEOMÉTRICAS

O registro de imagens é um dos primeiros passos a serem tomados no processo de tratamento e análise de imagens de sensoriamento remoto, visando a extração de informações espaciais. Dentre os objetivos deste procedimento estão:

- relacionamento entre coordenadas da imagem (linha e coluna) e coordenadas geográficas (latitude e longitude);
- combinar imagens obtidas por diferentes sensores ou a partir posições diferentes;
- corrigir distorções causadas pela posição do sensor ou pela curvatura da terra.

Ao contrário da seção anterior, na qual discutimos transformações radiométricas, neste caso, a correção é feita por meio de uma transformação geométrica, ou seja, o formato dos objetos da cena é modificado, e não seus níveis de cinza. Se não houver informação adicional sobre a transformação, a não ser as próprias imagens ou suas coordenadas geográficas, a transformação é determinada baseando-se em pares de pontos denominados *pontos de controle*. Estes pontos identificam a mesma posição em duas imagens diferentes e são usados para obter funções que mapeiam as coordenadas de uma imagem nas de outra imagem ou de um mapa (Jensen, 1996).

A determinação dos pontos de controle pode ser feita identificando-se visualmente pontos que claramente representem a mesma posição nas duas imagens. Para se obter melhores resultados com esta técnica é preciso que os pontos de controle escolhidos estejam bem distribuídos ao longo de toda a área da imagem.

Uma vez determinados os pontos de controle, seja manualmente ou por técnicas de registro translacional, o passo seguinte é definir a transformação geométrica a ser aplicada na imagem. Esta transformação é definida por uma função do tipo,

$$f(x, y) = (x', y')$$

onde,

$$x' = f_x(x, y)$$

$$y' = f_y(x, y)$$

Esta função mapeia as coordenadas dos pixels da imagem, de modo a corrigir as distorções. Entretanto, como estamos lidando com imagens digitais, o que significa que temos um conjunto discreto de pontos distribuídos ao longo de uma grade com coordenadas inteiras, o mapeamento por si só não é suficiente, uma vez que as coordenadas resultantes, x' e y' , podem não ser inteiras. É necessário portanto que haja, além da transformação geométrica, um esquema de interpolação para estimar os valores dos pontos com coordenadas inteiras. Nas seções a seguir descrevemos estes dois procedimentos.

3.2.1. Transformação de Coordenadas

Uma das finalidades da transformação de coordenadas é corrigir distorções causadas pelo sistema de imageamento e distorções devidas à posição do sistema. Quando não se dispõe de informação sobre o processo de distorção, a função de transformação deve ser inferida das próprias imagens ou dos pontos de controle. O

procedimento mais comum é supor que a função pode ser aproximada por polinômios, geralmente do segundo grau como:

$$x' = a_0 + a_1x + a_2y + a_3x^2 + a_4y^2 + a_5xy$$

$$y' = b_0 + b_1x + b_2y + b_3x^2 + b_4y^2 + b_5xy$$

A transformação fica perfeitamente conhecida se forem determinados os coeficientes a_i e b_i ($i = 0, 1, \dots, 5$), os quais podem ser obtidos através dos pontos de controle definidos nas imagens. Uma das operações mais simples, e ainda assim de grande utilidade, é a chamada *transformação afim*, que envolve operações como translação, mudança de escala, rotação, entre outras. Estas operações podem ser totalmente representadas por polinômios do primeiro grau do tipo:

$$x' = a_0 + a_1x + a_2y$$

$$y' = b_0 + b_1x + b_2y$$

O número mínimo de pontos de controle necessários para a determinação dos coeficientes de um polinômio de grau n é dado pela expressão:

$$c(n) = \frac{n^2 + 3n + 2}{2}$$

Entretanto, devido a possíveis erros existentes na localização dos pontos de controle, costuma-se tomar mais pontos de controle que o estritamente necessário, escolhendo os coeficientes de modo a minimizar o erro. Este procedimento torna-se conveniente também, levando-se em conta que nem sempre o polinômio escolhido é suficiente para modelar a transformação.

3.2.2. Interpolação

Após a transformação de coordenadas, os pontos da imagem podem ficar distribuídos ao longo de uma grade irregular, isto é, as coordenadas (x', y') resultantes da transformação podem não ser inteiras e não estarem alinhadas vertical ou horizontalmente. Entretanto, para a representação digital de imagens, é necessário que se tenha pontos alinhados ao longo de uma grade regular com coordenadas iguais às da imagem original. Para isto é preciso que se façam estimativas dos níveis de cinza nas coordenadas desta grade baseando-se nos níveis dos pontos disponíveis. Isto é obtido através de esquemas de interpolação.

O esquema mais simples e rápido de interpolação é o utilizado no *interpolador por vizinho mais próximo* (também chamado *interpolador de ordem zero*). Neste método, para cada posição (x, y) da grade regular, atribui-se o nível de cinza da coordenada transformada (x', y') mais próxima. Um inconveniente deste método é que ele pode introduzir descontinuidades na imagem resultante. Este efeito em geral é pouco perceptível visualmente mas pode ter consequências indesejáveis para uma posterior análise numérica das imagens.

Uma imagem mais suavizada pode ser obtida usando-se o *interpolador bilinear* (ou *interpolador de primeira ordem*). Neste esquema, o cálculo de cada nível de cinza na grade regular é baseado nos níveis de cinza dos quatro vizinhos mais próximos. Em geral, este interpolador utiliza funções lineares que atuam separadamente sobre x e

y para fazer cada estimativa. A desvantagem deste método, com respeito ao interpolador por vizinho mais próximo, é seu maior custo computacional, pois precisa executar um número muito maior de operações aritméticas.

As duas técnicas que citamos acima são capazes de produzir resultados satisfatórios para a maioria das aplicações, entretanto, para casos que exijam maior precisão, existem técnicas de interpolação mais apuradas. Como exemplos de tais técnicas podemos citar a interpolação gaussiana ou a interpolação por *B-splines* cúbicas (Pratt, 1991). Estas técnicas são capazes de produzir resultados melhores, entretanto, o custo computacional pode aumentar consideravelmente.

3.3. RESTAURAÇÃO E REGISTRO DE IMAGENS NO SPRING

Para correção radiométrica de imagens, o SPRING dispõe de uma série de filtros para remoção de ruído: os filtros de média e mediana para ruídos em geral; os filtros de Lee, Frost e Kuan para o ruído *speckle*; um filtro para correção do efeito de *line drop-out*, que é capaz de corrigir tanto linhas excessivamente escuras quanto linhas excessivamente claras (Eliminação de Ruído); e filtros específicos para correção de imagens provenientes dos sensores TM/Landsat e HVR/Spot (Restauração).

Além destes, existe também a possibilidade de criar novos filtros com máscaras específicas para outros tipos de distorções, utilizando-se a opção de edição de máscaras.

Com relação a registro, as imagens podem ser relacionadas a um mapa ou a outra imagem. Os pontos de controle são determinados de maneira manual, diretamente sobre a imagem e o sistema permite que novos pontos sejam criados, movidos ou eliminados a qualquer momento, até que se obtenha a melhor combinação de pontos de controle.

Para a transformação geométrica são oferecidas as opções de polinômios do primeiro e do segundo grau. Quando as transformações necessárias resumem-se a alterações de escala, translações ou rotações, polinômios do primeiro grau são suficientes. Entretanto, se houver necessidade de corrigir distorções mais complexas, como por exemplo as produzidas pela curvatura da terra, torna-se necessário o uso de polinômios do segundo grau.

Como interpolação o SPRING adota uma técnica denominada *interpolação híbrida*, que consiste de uma combinação entre o interpolador por vizinho mais próximo e o bilinear. O interpolador por vizinho mais próximo, que tem a vantagem de usar somente níveis de cinza que já existiam na imagem original, é aplicado nas regiões mais homogêneas da imagem. Para as regiões mais heterogêneas, é aplicado o interpolador bilinear, que produz uma imagem mais suavizada, acrescentando, contudo, novos níveis de cinza na imagem.

4. REALCE DE IMAGENS

As técnicas de realce visam basicamente melhorar o aspecto visual da imagem ou enfatizar alguma característica de interesse na cena. Este é um passo intermediário no processo de tratamento e análise de imagens de sensoriamento remoto. Deve ser feito após a restauração e registro, e antes da classificação.

Um problema que normalmente surge quando lidamos com algoritmos de realce, é a decisão sobre até que ponto o método realmente melhora a qualidade da imagem, já que isto é baseado em conceitos subjetivos. Muitas vezes um método pode obter um ótimo resultado para um determinado tipo de imagem, e entretanto piorar a qualidade de uma outra. Devido a isto, a maioria das técnicas de realce são desenvolvidas de maneira empírica e permitem que o usuário atinja iterativamente o resultado desejado.

Neste capítulo, daremos uma visão geral sobre as técnicas mais comuns utilizadas para realce de imagens, as quais podem ser classificadas nas seguintes categorias: *manipulação de contraste, filtragem, coloração e operações entre bandas*.

4.1. MANIPULAÇÃO DE CONTRASTE

Diz-se que o contraste entre dois objetos em uma cena é baixo, quando a diferença entre os valores médios de seus níveis de cinza é pequena. É muito comum a ocorrência de imagens de sensoriamento remoto com pouca variação de níveis de cinza, e esta característica pode dificultar a distinção entre os objetos da cena e, conseqüentemente, a análise da imagem. A técnica mais comum para melhorar o aspecto de tais imagens, é por meio de operações pontuais, nas quais cada pixel da imagem é tratado de maneira independente, sem levar em conta sua relação com a vizinhança. Estas técnicas consistem de transformações radiométricas, onde cada nível de cinza x é mapeado em um outro nível de cinza y por meio de uma função $f: [0, M] \rightarrow [0, M]$, convenientemente escolhida (a notação $[0, M]$ representa o intervalo de níveis de cinza da imagem no qual 0 é o preto e M é o branco). A Figura 4.1 mostra um exemplo do efeito que pode ser causado por operações deste tipo.

A escolha da operação a ser utilizada na manipulação de contraste, em geral, é baseada no *histograma de níveis de cinza* da imagem (Castleman, 1979), que é dado por uma função $h: [0, M] \rightarrow [0, 1]$ definida por:

$$h(n) = \frac{p(n)}{M}$$

onde $p(n)$ representa o número total de ocorrências do nível de cinza n , e M é o número total de pixels na imagem.




FIGURA 4.1. Imagem original (acima) e com realce de contraste (abaixo).

4.1.1. Transformações com Funções Predefinidas

Uma série de funções predefinidas pode ser utilizada para definir diferentes transformações radiométricas de manipulação de contraste. A escolha da função mais adequada irá depender das características da imagem original e do resultado esperado. Em geral estas transformações são definidas através de mapeamentos do tipo:

$$y = \begin{cases} 0 & \text{se } x < \alpha \\ f(x) & \text{se } \alpha \leq x \leq \beta \\ N & \text{se } x > \beta \end{cases}$$

onde x e y são os valores dos níveis de cinza original e resultante, N é o valor máximo de nível de cinza que a imagem pode ter, f é uma função predefinida com alguns parâmetros ajustáveis, e α e β são os limites máximo e mínimo de níveis de cinza, sobre os quais a função f atua. É conveniente que estes limites sejam escolhidos com base no histograma, de tal forma que:

$$h(n) = 0, \text{ se } n < \alpha \text{ ou } n > \beta$$

A escolha da função a ser utilizada depende das características da imagem original e dos objetivos a serem atingidos. Alguns exemplos de funções que podem ser utilizadas são:

- **Linear positivo:** $f(x) = a(x - b)$; com uma escolha conveniente dos parâmetros α e β , pode ser usada para expandir o intervalo de valores de tons de cinza da imagem, aumentando seu contraste como um todo.
- **Linear negativo:** $f(x) = -a(x - b)$; neste caso as regiões claras da imagem tornam-se escuras e vice-versa, produzindo um efeito semelhante ao negativo de uma fotografia.
- **Raiz quadrada:** $f(x) = a\sqrt{x - b}$; aumenta o contraste das regiões mais escuras da imagem.
- **Quadrado:** $f(x) = a(x - b)^2$; aumenta o contraste das regiões mais claras da imagem.
- **Logaritmo:** $f(x) = a \log(x - b)$; assim como a raiz quadrada, também é usado para realçar regiões escuras da imagem, mas neste caso o realce é feito sobre um intervalo menor de níveis de cinza.

Em todas as funções acima, os parâmetros a e b são números positivos, calculados com base nos limites α e β fornecidos. No mapeamento que é mostrado acima, supõe-se que a função f seja crescente no intervalo $[\alpha, \beta]$, logo, seus parâmetros devem ajustados de tal forma que $f(\alpha) = 0$ e $f(\beta) = N$, de modo a manter a continuidade no mapeamento. Se a função for decrescente, como é o caso da linear negativa, há uma pequena modificação na definição do mapeamento:

$$\begin{aligned} y &= N \text{ se } x < \alpha \\ y &= 0 \text{ se } x > \beta \end{aligned}$$

Neste caso os parâmetros a e b são ajustados de modo que $f(\alpha) = N$ e $f(\beta) = 0$.

4.1.2. Equalização de Histograma

Na operação de *equalização de histograma* (Pratt, 1991), a função usada no mapeamento é definida de modo que a imagem resultante tenha um histograma aproximadamente uniforme. Esta função pode ser definida como:

$$f(n) = N \sum_{i=0}^n h(i)$$

onde N é o maior valor de nível de cinza e h é a função que descreve o histograma da imagem original. Como resultado, os níveis de cinza da imagem são distribuídos de maneira aproximadamente constante ao longo de todo o intervalo $[0, N]$ e, conseqüentemente, tanto as áreas escuras quanto as áreas claras têm seu contraste realçado.

4.2. FILTRAGEM

As técnicas de filtragem podem ser utilizadas, basicamente, com dois objetivos: remoção de ruído ou realce de certos elementos da imagem. No capítulo anterior falamos sobre algumas técnicas de filtragem para remoção de ruído. Nesta seção falamos um pouco mais sobre o mecanismo de funcionamento dos filtros e sobre como eles podem ser utilizados para destacar certas características das imagens. As técnicas de filtragem também consistem de transformações radiométricas, mas neste caso, as operações são feitas levando-se em conta também, uma vizinhança de cada pixel. Os filtros mais comuns podem ser divididos em dois grupos: *lineares* e *não-lineares*.

4.2.1. Filtros Lineares

Nos filtros lineares, a transformação é feita através da convolução entre a imagem e uma máscara definida por uma função bidimensional discreta. Dada uma imagem u com $M \times N$ pixels e uma máscara g , a imagem filtrada v , é obtida por uma operação do tipo (Castleman, 1979):

$$v(k, l) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} u(m, n) g(k - m, l - n)$$

Estas máscaras são definidas de modo que possuam valores não nulos somente em uma determinada vizinhança da posição $(0, 0)$, ou seja, elas são semelhantes a algo do tipo:

0	0	0	0	0
0	$g(-1, 1)$	$g(0, 1)$	$g(1, 1)$	0
0	$g(-1, 0)$	$g(0, 0)$	$g(1, 0)$	0
0	$g(-1, -1)$	$g(0, -1)$	$g(1, -1)$	0
0	0	0	0	0

Sendo assim, o cálculo de cada pixel $v(k, l)$, da imagem resultante, será afetado apenas por uma vizinha do pixel $u(k, l)$, da imagem original.

Estes filtros são utilizados para separar diferentes componentes de *freqüência espacial* na imagem. Diz-se que uma certa região da imagem possui alta freqüência espacial quando ela contém uma grande variação de níveis de cinza. Se esta variação é suave, diz-se que a região possui uma baixa freqüência espacial. Neste contexto, estes filtros podem ser divididos em três categorias: *passa-baixa*, *passa-alta* e *passa-banda* (Jain, 1989).

Os filtros passa-baixa removem as componentes de alta freqüência espacial da imagem, suavizando as regiões com variações bruscas de níveis de cinza. Estes filtros podem ser úteis na remoção de ruídos de alta freqüência, entretanto, podem produzir efeitos indesejáveis, como o borramento da imagem.

Os filtros passa-alta são aqueles que removem as componentes de baixa freqüência espacial na imagem, destacando assim suas bordas. São muito usados em aplicações que necessitam de detecção de contornos. A filtragem passa-alta pode ser conseguida através da convolução da imagem com uma máscara convenientemente definida, ou ainda calculando-se a diferença entre uma imagem resultante de filtragem passa-baixa e a imagem original.

Os filtros passa-banda ressaltam uma determinada faixa de freqüência espacial na imagem. Geralmente são usados para realce de bordas em imagens ruidosas. O tipo mais comum de filtro passa-banda é aquele obtido calculando-se a diferença entre imagens resultantes de dois filtros passa-baixa diferentes.

A Figura 4.2 mostra um exemplo do efeito causado em imagens por filtros passa-baixa e passa-alta.

A maneira mais direta de se obter um filtro passa-baixa é atribuir valores iguais a todas as posições não nulas da máscara. O filtro de média é o exemplo mais comum. Este filtro obtém, para cada pixel, a média (não ponderada) entre os valores dos níveis de cinza de uma vizinhança. Quanto maior for esta vizinhança mais suavizada será a imagem resultante. No caso de uma vizinhança de 3×3 elementos, o filtro é definido por uma máscara como a mostrada abaixo (os colchetes indicam a posição (0,0) da máscara):

$$\begin{array}{ccc} \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \left[\frac{1}{9} \right] & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{array}$$

Quanto maior for a máscara utilizada, mais embaçada será a imagem resultante. Para minimizar este efeito, pode-se, alternativamente, utilizar a média ponderada da vizinhança. Isto pode ser obtido, por exemplo, com uma máscara do tipo:

$$\begin{array}{ccc} \frac{1}{16} & \frac{1}{8} & \frac{1}{16} \\ \frac{1}{8} & \left[\frac{1}{4} \right] & \frac{1}{8} \\ \frac{1}{16} & \frac{1}{8} & \frac{1}{16} \end{array}$$

Observe que, em ambos os casos, o somatório de valores das máscaras é igual a 1, de modo que a luminância média da imagem não é alterada.

A idéia do filtro de média também pode ser usada em alguns filtros mais elaborados e capazes de preservar bordas. Pode-se, por exemplo, utilizar máscaras que se

adaptem a certas propriedades estatísticas da imagem. Exemplos de tais filtros foram propostos por Lee (1983) e Eliason & McEwen (1990).




FIGURA 4.2. Imagem original (a), filtro passa-baixa (b) e filtro passa-alta (c).

No caso dos filtros passa-alta, as máscaras podem ser projetadas para realce direcional ou não-direcional de bordas.

Os filtros de realce direcional de bordas são usados para ajudar na identificação de bordas em uma determinada direção e destacar características que podem ser de algum interesse na imagem, como por exemplo, sombreamentos associados a relevo ou lineações de drenagem. As máscaras de gradiente direcionais (*compass gradient masks*) (Pratt, 1991), que são mostradas abaixo, podem ser utilizadas com este objetivo.

1	1	1	1	1	1	-1	1	1	-1	-1	1
1	-2	1	-1	-2	1	-1	-2	1	-1	-2	1
-1	-1	-1	-1	-1	1	-1	1	1	1	1	1
norte			nordeste			leste					
sudeste											
-1	-1	-1	1	-1	-1	1	1	-1	1	1	1
1	-2	1	1	-2	-1	1	-2	-1	1	-2	-1
1	1	1	1	1	1	1	1	-1	1	-1	-1
sul			sudoeste			oeste					
noroeste											

Quando se emprega a máscara de gradiente *leste*, por exemplo, serão destacados os aumentos bruscos de luminância que ocorrem horizontalmente, da esquerda para a direita. Por outro lado, todas as regiões da imagem com pouca ou nenhuma variação de luminância nesta direção, serão pouco visíveis na imagem resultante. Nestes filtros, o somatório dos valores das máscaras é sempre zero, de modo que regiões homogêneas se anulam na imagem resultante.

Os filtros de realce não-direcionais são usados para detecção de bordas independentemente da direção. Nesta categoria estão os filtros *Laplacianos* (Pratt, 1991). Abaixo são mostradas algumas máscaras que são usadas nestes filtros.

-1	-1	-1	0	-1	0	1	-2	1
-1	8	-1	-1	4	-1	-2	4	-2
-1	-1	-1	0	-1	0	1	-2	1
(A)			(B)			(C)		

O realce de bordas é mais evidente com a máscara (A). Com a máscara (C) apenas as bordas mais acentuadas serão visíveis, e a máscara (B) é intermediária em as outras duas.

4.2.2. Filtros Não-lineares

Alguns filtros não-lineares também usam a operação de convolução, mas não são baseados apenas neste procedimento. Nesta categoria incluem-se os operadores de gradiente e os filtros morfológicos.

4.2.2.1. Operadores de Gradiente

Os chamados *operadores de gradiente*, são, na verdade, filtros passa-alta representados por um par de máscaras h_1 e h_2 , que são usadas para medir o gradiente em cada ponto da imagem em duas direções ortogonais. Uma vez medidos os gradientes direcionais g_1 e g_2 , através de uma convolução entre a imagem e as máscaras, a magnitude g e direção θ do vetor gradiente são dados, respectivamente, por:

$$g(m,n) = \sqrt{g_1^2(m,n) + g_2^2(m,n)}$$

$$\theta(m,n) = \tan^{-1} \frac{g_1(m,n)}{g_2(m,n)}$$

A vantagem deste tipo de filtragem sobre os filtros passa-alta lineares, é que, neste caso, se obtém uma informação mais completa a respeito das bordas, o que pode permitir análises mais apuradas. Abaixo mostramos os pares de máscaras utilizadas em alguns dos operadores de gradiente mais comuns (Jain, 1989).

Roberts	$\begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$
Prewitt	$\begin{bmatrix} -1 & 0 & 1 \\ -1 & [0] & 1 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & [0] & 0 \\ 1 & 1 & 1 \end{bmatrix}$
Sobel	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & [0] & 2 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & [0] & 0 \\ 1 & 2 & 1 \end{bmatrix}$
Isotrópico	$\begin{bmatrix} -1 & 0 & 1 \\ -\sqrt{2} & [0] & \sqrt{2} \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -\sqrt{2} & -1 \\ 0 & [0] & 0 \\ 1 & \sqrt{2} & 1 \end{bmatrix}$

4.2.2.2. Filtros Morfológicos

Estes filtros provêm de uma área de estudo em processamento digital de imagens, conhecida como *morfologia matemática* (Serra, 1982), que tem como objetivo extrair informações a respeito da forma ou estrutura topológica dos objetos presentes na imagem.

Eles se baseiam em um procedimento semelhante ao de convolução, mas, neste caso, ao invés de máscaras, são utilizados *elementos estruturantes*, e contém apenas 0's e 1's. As posições marcadas com valor 1, indicam quais pixels da vizinhança devem ser considerados na operação. A maioria das operações morfológicas são definidas em termos de duas operações básicas: *erosão* e *dilatação*.

A operação de erosão provoca, na imagem resultante, uma expansão de elementos escuros, cuja estrutura seja semelhante à do elemento estruturante. Isto é obtido substituindo-se o valor de cada pixel pelo menor valor entre os indicados pelo elemento estruturante.

A operação de dilatação é semelhante à de erosão e provoca uma expansão de elementos claros na imagem, substituindo o valor de cada pixel pelo maior valor entre os indicados pelo elemento estruturante.

Outras operações morfológicas podem ser obtidas a partir da combinação entre erosão e dilatação. Alguns exemplos:

- Abertura (erosão seguida de dilatação): suaviza contornos e suprime pequenos pontos claros isolados na imagem (Figura 4.3).
- Fechamento (dilatação seguida de erosão): suaviza contornos e suprime pequenos pontos escuros isolados na imagem (Figura 4.4).




FIGURA 4.3. Efeitos da operação de abertura.




FIGURA 4.4. Efeitos da operação de fechamento.

4.3. OPERAÇÕES ENTRE BANDAS

Neste tipo de operação, leva-se em conta a relação entre pixels na mesma posição em diferentes bandas de uma imagem multiespectral. Geralmente estas operações são realizadas ponto a ponto, sem levar em conta a vizinhança.

Uma idéia muito utilizada é a de realizar operações aritméticas entre os níveis de cinza dos pixels nas diferentes bandas. O cálculo de medidas estatísticas, tais como

média e desvio padrão, também podem ser usadas para destacar certas regiões da imagem.

Existe também uma técnica que pode ser usada não apenas para realçar detalhes, mas também para reduzir a quantidade de dados necessários para representar a imagem multi-espectral: a *transformação dos componentes principais*. Esta transformação tem a propriedade de concentrar a maior parte da informação contida em 7 ou 8 bandas em apenas 2 ou 3 imagens, destacando assim vários detalhes que pareciam imperceptíveis ao se examinar cada banda separadamente.

Nas seções seguintes, falamos mais detalhadamente sobre estas técnicas.

4.3.1. Operações Aritméticas

Existe uma série de operações aritméticas, que podem ser realizadas, pixel a pixel, usando-se diferentes bandas de imagens multiespectrais. São utilizadas operações como soma, subtração, multiplicação e divisão entre os níveis de cinza da imagem. Estas operações podem requerer também um fator de ganho (multiplicativo) e *off-set* (aditivo), que podem servir para melhorar a qualidade de contraste da imagem. O objetivo destas operações pode ser o realce de alguma característica de interesse na imagem, ou ainda, compressão de dados diminuindo a quantidade de bandas, ocasionando, contudo, perda de parte da informação original.

Quando a média e desvio padrão dos níveis de cinza das bandas a serem usadas nas operações não coincidirem, é aconselhável executar, antes, a equalização dos histogramas, ou outra operação capaz de aproximar estes valores, pois do contrário o resultado obtido pode não corresponder ao esperado. Conhecendo-se as curvas de comportamento espectral dos alvos de interesse e o intervalo espectral das bandas dos sensores, é possível definir quais bandas serão utilizadas nas operações para realçar as características desejadas. A seguir damos alguns exemplos de operações que podem ser realizadas entre duas bandas X e Y , onde a e b representam fatores de ganho e *off-set*.

- $a(X - Y) + b$: a subtração entre bandas espectrais pode ser usada para aplicações tais como: identificação de diferentes tipos de cobertura vegetal; detecção do padrão de mudança de coberturas, tais como, uso de solo, expansão urbana e desmatamento.
- $a(X + Y) + b$: a adição de imagens pode ser usada para obtenção da média aritmética entre os níveis de cinza, usando-se um ganho de $1/2$, ou ainda para integrar imagens resultantes de diferentes processamentos.
- $a(X/Y) + b$: a divisão (ou razão) entre bandas não é aconselhável para imagens ruidosas, pois o ruído tende a ser realçado. Esta operação pode ser usada para: remover efeitos provenientes de variações espaciais ou temporais, quando ocorrem em bandas de uma mesma imagem; diminuir variação de luminância da imagem, provenientes de efeito de topografia, declividade e aspecto; aumentar diferenças de luminância entre solo e vegetação.
- $aX + b$: a multiplicação por escalar pode ser usada para expandir ($a > 1$) ou contrair ($a < 1$) os valores dos níveis de cinza da imagem, antes que esta seja usada em outras operações ou processamentos.

- $a((X - Y)/(X + Y)) + b$: quando X é a banda do infravermelho próximo e Y é a banda do vermelho, esta operação corresponde ao *índice de vegetação normalizada* (Lillesand & Kiefer, 1994), que além de aumentar o contraste entre vegetação e o solo, também produz uma compensação parcial dos efeitos de iluminação, declividade da superfície e geometria da visada.

4.3.2. Componentes Principais

É muito comum que haja uma grande correlação entre as bandas de uma imagem multi-espectral, pois algumas bandas tendem a ser visual e numericamente muito semelhantes entre si. Sendo assim, a análise das bandas espectrais pode tornar-se ineficiente devido à grande quantidade de redundância presente nas imagens. A *transformação dos componentes principais* (Pratt, 1991) é uma técnica que permite reduzir esta redundância, pois tem a propriedade de concentrar a maior parte da informação em um pequeno número de bandas, realçando assim algumas características que antes poderiam estar ocultas.

Esta transformação é derivada da matriz de covariância entre as bandas. Neste caso, uma imagem multiespectral de n bandas é vista como um conjunto vetores de n posições que representam seus pixels. A transformação é feita em cada um destes vetores individualmente e é equivalente a uma rotação em um espaço n -dimensional. Como resultado obtém-se n bandas, correspondendo às n posições dos vetores, que são ordenadas de maneira decrescente com relação à variância de seus níveis de cinza. Para se atingir este resultado, é feita uma rotação no espaço n -dimensional de tal forma que o eixo referente à primeira componente aponte na direção em que há maior variação nos vetores originais, e o eixo da última componente passa a apontar na direção em que há menor variação. Esta rotação é obtida por uma matriz A cujas linhas são os autovetores da matriz de covariância C . Para obter esta matriz basta observar que ela obedece a seguinte propriedade:

$$ACA^T = D$$

onde D é uma matriz cuja diagonal principal contém os autovalores de C e tem todas as demais posições nulas. Os autovalores serão proporcionais às variâncias das componentes principais. Uma vez obtida a matriz A , para cada vetor original u , obtém-se um vetor de componentes principais v através da operação:

$$u = Av$$

Nesta representação assumimos que u e v são matrizes colunas.

A primeira componente principal contém a informação de brilho e possui a maior parte da informação contida nas imagens. As demais componentes apresentam gradativamente menos contraste e as últimas componentes representam basicamente o ruído existente nos dados originais.

4.4. COLORAÇÃO

O olho humano é capaz de distinguir muito mais cores do que tons de cinza. A percepção de detalhes da cena pode aumentar sensivelmente pela introdução de cores na imagem.

Uma das maneiras mais diretas de se introduzir cores em uma imagem monocromática é através do *fatiamiento de níveis de cinza*. Neste procedimento, também chamado de *pseudocoloração*, a escala de níveis de cinza é dividida em intervalos disjuntos, e para cada um deles é atribuída uma cor, definida por uma diferente combinação de vermelho, verde e azul.

No caso de estarmos lidando com imagens com mais de uma banda espectral, uma alternativa é mapear as diferentes bandas nos valores de vermelho, verde e azul, permitindo assim, que as informações contidas em três bandas espectrais diferentes possam ser visualizadas de maneira simultânea. Com este procedimento, podem ser revelados alguns detalhes que não são visíveis quando as bandas são observadas isoladamente.

A coloração pode ser obtida também utilizando-se transformações radiométricas diferentes para os níveis de vermelho, verde e azul em uma mesma imagem. As funções usadas nestas transformações podem ser semelhantes àquelas usadas na manipulação de contraste.

4.5. REALCE DE IMAGENS NO SPRING

O SPRING dispõe de uma grande variedade de técnicas de realce de imagens envolvendo manipulação de contraste, filtragem, operações entre bandas e coloração. As técnicas disponíveis no sistema são suficientes para a maioria das aplicações de sensoriamento remoto e são descritas nas seções a seguir.

4.5.1. Manipulação de Contraste

O SPRING possui um módulo de manipulação de contraste, que contém a operação de equalização de histograma e algumas funções pré-definidas como: linear (positiva e negativa), quadrática, raiz quadrada e logaritmo. Além destas, o sistema permite também que o usuário defina iterativamente a função a ser utilizada na transformação radiométrica. O usuário pode editar a curva que define esta função, e ao mesmo tempo verificar o resultado da transformação na imagem. A edição é feita dividindo-se a curva em vários segmentos. Para cada um destes segmentos o sistema, baseado nas coordenadas fornecidas pelo usuário, determina uma função linear que atua sobre o respectivo intervalo. O resultado é uma combinação contínua de funções lineares que é usada para fazer a transformação radiométrica.

Esta ferramenta pode ser muito útil para se destacar aspectos específicos na imagem ou para realçar imagens cujo histograma é assimétrico, nas quais uma transformação linear simples não é suficiente. Esta operação pode ser utilizada também para destacar grupos de níveis de cinza, que possam ter algum interesse especial.

4.5.2. Filtragem

O módulo de filtragem do SPRING oferece vários tipos diferentes de filtros, os quais podem ser utilizados para uma grande variedade de aplicações.

Entre os filtros lineares, estão disponíveis os seguintes filtros de convolução:

- Passa-baixa - filtro de média não ponderada com máscaras de tamanho 3x3, 5x5 e 7x7.
- Direcional de borda - estão disponíveis as máscaras de gradiente direcionais citadas na Seção 4.2.1.
- Não direcional de borda - estão disponíveis as máscaras Laplacianas citadas na Seção 4.2.1.
- Realce de Imagem TM - máscara desenvolvida com base nas características espectrais de imagens provenientes do sensor Landsat/TM.

Além das máscaras predefinidas, o SPRING oferece também um editor de máscaras para filtros de convolução (lineares). Deste modo o usuário pode criar, atualizar, suprimir e aplicar suas próprias máscaras.

Entre os filtros não lineares estão disponíveis os seguintes:

- Detecção de bordas - operadores de gradiente de Sobel e Roberts.
- Filtro de mediana (veja Seção 3.1.2).
- Filtros morfológicos de erosão e dilatação.
- Filtros de ruído Speckle (veja Seção 3.1.2) - Lee, Kuan e Frost.

Para a aplicação dos filtros morfológicos, o sistema provê sete elementos estruturantes predefinidos, os quais são mostrados abaixo:

1	1	1	1	0	1	0	1	0	0	0	0
1	[1]	1	0	[1]	0	1	[1]	1	1	[1]	1
1	1	1	1	0	1	0	1	0	0	0	0

0	1	0	0	0	1	1	0	0
0	[1]	0	0	[1]	0	0	[1]	0
0	1	0	1	0	0	0	0	1

Existe também um editor para filtros morfológicos que permite que o usuário defina novos elementos estruturantes para suas aplicações.

4.5.3. Operações Entre Bandas

Estão disponíveis no SPRING, a transformação dos principais componentes e algumas operações aritméticas pré-definidas, como soma, subtração, multiplicação (entre imagens ou por escalar), razão e a operação para índice de vegetação normalizada. O sistema permite que o usuário ajuste os parâmetros de ganho e *offset* de acordo com seus objetivos.

4.5.4. Coloração

A maneira mais direta de se obter coloração de imagens no SPRING é através de composições coloridas entre diferentes bandas da imagem. Estas composições são

feitas atribuindo-se aos níveis de vermelho, verde e azul, os valores dos níveis de cinza de três bandas espectrais diferentes.

Uma outra maneira de se atribuir cores a imagens no SPRING é através de fatiamento de níveis de cinza. Existem três tipos de técnicas de fatiamento no SPRING:

- **Fatiamento normal:** as fatias são definidas de modo que o intervalo entre cada faixa seja constante.
- **Fatiamento por equidistribuição:** a escala de níveis de cinza é dividida de modo que cada faixa contenha o mesmo número de pontos.
- **Fatiamento arco-íris:** para cada tom de cinza é atribuída uma cor de uma escala contínua que vai de vermelho a violeta.

Uma outra ferramenta que o sistema oferece é a transformação $IHS \leftrightarrow RGB$. Para interpretar as propriedades de cor de um objeto em uma cena, o sistema visual humano em geral não distingue as proporções de vermelho, verde e azul, e sim, avalia a *intensidade* (I), a *cor* (H) e a *saturação* (S).

A intensidade, ou luminância, é a medida da energia total envolvida em todos os comprimentos de onda; a cor, ou matiz, é a medida do comprimento de onda médio da luz que se reflete ou se emite; e a saturação, ou pureza expressa, é dada pela largura do intervalo de comprimentos de onda ao redor do valor médio. Quando este intervalo é pequeno diz-se que a cor é muito saturada ou tem um alto grau de pureza, resultando em cores vivas. Quando o intervalo é grande diz-se que a cor é pouco saturada, o que indica uma mistura de comprimentos de onda que resulta em tons pastéis.

Por serem independentes, estes três parâmetros podem ser analisados e modificados separadamente para um melhor ajuste das cores às características do sistema visual.

A transformação dos componentes vermelho, verde e azul (RGB) nos componentes intensidade, matiz e saturação (IHS) são feitas através de algoritmos matemáticos que relacionam o espaço RGB ao IHS.

Para produzir composições coloridas, escolhem-se três bandas de uma imagem e associa-se cada banda a um dos componentes RGB. Executando-se a transformação IHS pixel a pixel, cada pixel na imagem de saída possuirá uma correspondência a um ponto no espaço IHS. O resultado é um conjunto de três novas imagens: uma de intensidade, uma de matiz e outra de saturação. Estas imagens são realçadas de modo a expandir o intervalo de intensidade e saturação através das técnicas convencionais de contraste, e novamente transformadas para o sistema RGB, permitindo assim, melhor separação das feições que se deseja observar.

De maneira análoga, a transformação pode ser feita também no sentido oposto, ou seja, do espaço IHS para o RGB. Esta transformação pode ser útil para produzir composições coloridas entre bandas que são muito semelhantes entre si, com um melhor aproveitamento do espaço de cores.

5. ANÁLISE DE IMAGENS

O objetivo final de um grande número de aplicações de processamento de imagens é a extração de informações relevantes da imagem, a partir das quais, se pode obter uma descrição, interpretação ou entendimento da cena. Foi com este objetivo que foram desenvolvidas as técnicas de análise de imagens e os chamados *sistemas de visão computacional* (Ballard & Brawn, 1982), que são capazes de interpretar os resultados de diferentes tipos de processamento e descrever os vários objetos presentes na imagem e sua relação com a cena. Neste sentido, a análise de imagens é um pouco diferente de operações tais como realce, cujo objetivo é apenas a transformação da imagem. Neste caso, teremos também uma divisão da imagem em diferentes categorias, as quais podem representar características e objetos de interesse na cena.

Atualmente, já existem sistemas de visão computacional bastante sofisticados. Para algumas aplicações industriais, por exemplo, existem robôs que são capazes de localizar e identificar diferentes tipos de peças e componentes sem nenhuma interferência humana. Outros exemplos de aplicações desses sistemas são as identificações automáticas de assinaturas, impressões digitais e até mesmo rostos de pessoas.

Em aplicações ambientais, entretanto, o problema tende a adquirir uma complexidade muito maior do que nos exemplos acima. Com a tecnologia disponível atualmente, ainda não é possível a extração, de forma totalmente automática, de toda a informação relevante que pode estar contida em imagens de sensoriamento remoto. A interferência humana ainda é indispensável. A dificuldade ocorre devido a vários fatores, por exemplo:

- diferentes classes de uso do solo ou recursos naturais podem produzir padrões de resposta espectral muito semelhantes;
- padrões de resposta espectral podem variar bastante ao longo do tempo ou devido a localização geográfica da área imageada;
- interferências atmosféricas e variações climáticas podem afetar de maneira significativa o padrão de resposta espectral.

Apesar das dificuldades, é inegável que as técnicas de processamento digital de imagens são de grande utilidade durante o processo de análise de imagens de sensoriamento remoto. Neste processo, inicialmente a imagem é pré-processada por meio de técnicas como as de restauração e realce, que discutimos nos capítulos anteriores. Em seguida, a imagem pode ser segmentada em componentes que representem diferentes feições. Por fim, é feita a classificação, e a imagem é dividida em regiões às quais podem ser atribuídos rótulos, que representam diferentes categorias temáticas. Desta forma poderá ser feita a interpretação da imagem, de modo a relacionar cada objeto ao contexto da cena.

Para chegar a este objetivo, são necessárias ferramentas de extração de feições, segmentação e classificação. No capítulo anterior, são citadas algumas técnicas de extração de feições, como os filtros de detecção de bordas e morfológicos. Em seções posteriores daremos uma breve descrição das principais técnicas de segmentação e classificação, mas antes introduziremos alguns conceitos que são bastante relevantes em análise de imagens.

5.1. TIPOS DE FEIÇÕES EM IMAGENS

Existe uma grande variedade de técnicas para extração de feições de imagens. Estas técnicas têm como objetivo detectar certas características que podem ser utilizadas para identificar diferentes tipos de objetos na cena. Há várias abordagens diferentes baseadas em características tais como amplitude, forma, bordas, contornos, textura, propriedades estatísticas, entre outras.

5.1.1. Feições Espaciais

As feições espaciais de um objeto podem ser caracterizadas por seus níveis de cinza ou pela distribuição de probabilidade dos mesmos. Uma das características mais simples e usuais de um objeto é a amplitude de suas propriedades físicas como, por exemplo, sua reflexividade. Estas características são representadas na imagem pelos diferentes níveis de cinza (ou cores), e podem ser facilmente extraídas por fatiamento ou outras técnicas pontuais de realce que citamos no capítulo anterior.

Existem também feições baseadas no histograma de regiões da imagem. Em geral estas feições são extraídas fazendo-se medições estatísticas, tais como média, variância ou desvio padrão, sobre pequenas janelas movendo-se ao longo da imagem. Isto pode ser útil, por exemplo, na segmentação da imagem em regiões de alto e baixo contraste.

No caso de imagens multi-espectrais os pixels podem também ser considerados como vetores, cujas coordenadas representam as bandas da imagem. As relações entre estes vetores, tais como distância ou distribuição de probabilidade, também podem ser usadas para segmentar a imagem ou caracterizar diferentes objetos da cena.

5.1.2. Bordas e Contornos

O problema de detecção de bordas e contornos é de fundamental importância na análise de imagens. As bordas são os locais da imagem onde há mudança brusca de níveis de cinza. São elas que caracterizam os contornos, que servem para representar as propriedades geométricas dos objetos da cena, tais como forma e tamanho.

A detecção de contornos pode ser feita de várias maneiras, mas talvez a técnica mais comum seja a de perseguir sucessivas bordas utilizando-se apenas a informação local, como amplitude e direção, que podem ser obtidos pelos operadores de gradiente que citamos na Seção 4.2.2. Uma vez encontrados os contornos, eles são geralmente representados por linhas poligonais ou por curvas suavizadas como *splines*.

5.1.3. Textura

O termo textura geralmente se refere à repetição de elementos básicos chamados *texels*. Um texel contém vários pixels, e seu posicionamento pode ser periódico, quase periódico ou aleatório. Texturas naturais geralmente são aleatórias, enquanto que texturas artificiais são freqüentemente determinísticas ou periódicas. Texturas podem ser também grossas, finas, suaves, granuladas, onduladas, regulares, irregulares ou lineares. Entretanto, no âmbito da análise de imagens, texturas podem

ser classificadas em duas categorias principais: *estatísticas* ou *estruturais* (Haralick, 1979).

A abordagem estatística é a mais recomendável para caracterizar texturas encontradas aleatoriamente na natureza. Neste caso, pode-se determinar as características da textura, tais como rugosidade, espessura e orientação utilizando-se técnicas de filtragem, e fazendo-se medições estatísticas, tais como média, variância e autocorrelação.

No caso de texturas estruturais, nas quais os texels são determinísticos e se repetem segundo alguma regra de posicionamento, a abordagem mais comum consiste em isolar, por identificação, um grupo de pixels que têm certas propriedades constantes que se repetem ao longo da imagem. O texel pode ser definido por seus tons de cinza, forma, ou homogeneidade de alguma propriedade local, tal como tamanho, orientação ou histograma. As regras de posicionamento definem o relacionamento espacial entre os texels.

5.1.4. Forma de Objetos

Entenda-se aqui a palavra forma como referindo-se ao perfil e à estrutura física do objeto. Estas feições podem ser basicamente divididas em geométricas ou baseadas em momento (Jain, 1989). Algumas feições geométricas de interesse são: área, perímetro, distâncias máximas e mínimas ao centro de massa, número de buracos (NB), número de regiões conexas (NC), número de Euler ($NC - NB$), simetria, entre outras. Dentre as feições baseadas em momentos estão: centro de massa, orientação (direção do eixo com menor momento de inércia), retângulo envolvente, excentricidade. Estas características podem ser representadas por diversos tipos de modelos, os quais podem ser utilizadas para detecção e reconhecimento de objetos em uma cena ou para fazer medições sobre os mesmos. A seguir citamos alguns exemplos de modelos muito utilizados para representação de forma.

- **Contornos:** é a representação vetorial dos objetos. Uma das mais usuais, pois conserva várias propriedades geométricas dos objetos e também é adotada em síntese de imagens (computação gráfica).
- **Regiões:** A forma de um objeto pode ser diretamente representada pela região que ele ocupa em uma representação por varredura. Este tipo de representação ocupa uma quantidade muito maior de memória que a representação por contornos (vetorial), mas permite uma descrição da cena com maior precisão de detalhes.
- **Estruturas:** Em muitas aplicações de análise de imagens os objetos na cena podem ser caracterizados de maneira satisfatória por estruturas compostas apenas por linhas e arcos. São situações em que a espessura do objeto é irrelevante para o processo de análise, logo, o que se deseja é apenas o "esqueleto" do objeto. Filtros morfológicos tais como erosão e dilatação são muito úteis nestes casos.

5.2. SEGMENTAÇÃO DE IMAGENS

Segmentação de imagens refere-se à decomposição da imagem em diferentes regiões representadas por conjuntos conexos de pontos. As regiões que se deseja detectar, em geral são áreas homogêneas, ou seja, que apresentam alguma

propriedade local aproximadamente constante em toda sua extensão. Algumas propriedades locais que podem ser utilizadas são distribuição de níveis de cinza e características de textura. As técnicas de segmentação podem ser baseadas em crescimento de regiões ou detecção de contornos.

Nas técnicas baseadas em crescimento de regiões, inicialmente cada pixel da imagem é considerado como sendo uma região, em seguida, pixels vizinhos vão sendo unidos entre si até formarem regiões atômicas, nas quais todos os pixels têm o mesmo tom de cinza. Daí para frente, as regiões que tiverem fronteiras em comum vão sendo agregadas umas as outras, desde que satisfaçam a certos critérios preestabelecidos. Estes critérios geralmente se baseiam em alguma medida de similaridade entre as regiões. Brice & Fennema (1977) propuseram um esquema que se baseia nas diferenças entre níveis de cinza nas fronteiras entre regiões. Entretanto, é utilizada também uma heurística, que leva em conta a razão entre o comprimento da fronteira e o perímetro das regiões, para fazer com que pequenas regiões sejam agregadas pelas grandes, antes que as maiores regiões sejam agregadas entre si.

Uma outra estratégia para segmentação de imagens é conhecida como *perseguição de contorno*. Antes de ser usada porém, é necessário que a imagem passe por um filtro de gradiente, como o de Sobel ou Roberts (ver Seção 4.2.2.1), para extrair informação sobre intensidade e direção das bordas.

Neste esquema, inicialmente define-se um limiar para perseguição de contorno. Quando o algoritmo encontra uma borda cuja intensidade seja maior que o limiar estabelecido, inicia-se o processo de perseguição. Observa-se a vizinhança para identificar o pixel com maior nível de cinza e segue-se nesta direção até que se encontre uma outra borda ou a fronteira da imagem. Ao longo do percurso, os pixels vão sendo marcados como parte do contorno. A perseguição continua até que se chegue a um pixel já marcado, concluindo assim o contorno. Em seguida, é procurada uma borda ainda não marcada e inicia-se a construção de um novo contorno. O processo continua até que todas as bordas, cuja intensidade seja maior que o limiar, estejam marcadas. Várias técnicas semelhantes a esta podem ser encontradas na literatura. Veja, por exemplo, os trabalhos de Martelli (1972) e Cederberg (1979).

5.3. CLASSIFICAÇÃO DE IMAGENS

A maioria das técnicas de classificação foram desenvolvidas visando aplicações de reconhecimento de padrões e vão além do escopo da análise de imagens. Existem muitos estudos teóricos e uma grande variedade de técnicas de classificação que podem ser encontradas na literatura especializada (Jensen, 1996; Lillesand & Kiefer, 1994; Jain, 1989). Nesta seção falaremos apenas sobre algumas técnicas mais comuns, que são relevantes no âmbito da análise de imagens de sensoriamento remoto. Estas técnicas podem ser aplicadas a imagens multiespectrais e são usadas para mapear áreas da superfície terrestre que apresentam o mesmo significado.

Os processos de classificação e segmentação têm objetivos intimamente ligados. Algumas técnicas de classificação usam segmentação e vice-versa. Classificação de pixels, por exemplo, é uma forma de rotulação de componentes que pode resultar na segmentação de vários objetos da imagem.

O resultado final de um processo de classificação é uma imagem digital, que constitui um mapa de pixels divididos em classes, as quais são distinguidas entre si por meio de cores diferentes. A cada uma destas classes pode ser atribuído um significado que identifique alguma característica das regiões representadas.

Basicamente, existem duas abordagens para classificação: *supervisionada* ou *não supervisionada*, dependendo de quando é usado ou não um processo de treinamento baseado em um conjunto de protótipos.

5.3.1. Classificação Supervisionada

Na classificação supervisionada, às vezes assume-se que são conhecidas as funções de distribuição de probabilidade das respostas espectrais nas diferentes bandas, exceto por alguns parâmetros. Neste caso, o processo de treinamento tem o objetivo de fazer uma estimativa dos parâmetros desconhecidos dessas funções. Este processo é feito a partir de uma seleção visual de pequenas regiões, na imagem, que sejam representativas das diferentes classes temáticas. Exemplos de métodos que usam esta estratégia são os chamados *classificadores estatísticos*, dentre os quais o mais comum é o *classificador por máxima verossimilhança*⁷ (Jensen, 1996; Lillesand & Kiefer, 1994), popularmente conhecido como MAXVER.

No esquema do MAXVER, os pixels de uma imagem multi-espectral de n bandas são considerados como pontos de um espaço n -dimensional, e assume-se que as respostas espectrais, nas diferentes classes, possuem distribuição de probabilidade normal (Gaussiana). A fase de treinamento, então, tem o objetivo de determinar os parâmetros desconhecidos na função de distribuição, ou seja, média e matriz de covariância.

Uma vez determinadas as distribuições de probabilidade de cada uma das classes, o critério de similaridade usado na classificação será a probabilidade dos pixels pertencerem a determinadas classes. Cada pixel é então agregado à classe à qual tem maior probabilidade de pertencer.

Existem também estratégias que não são baseadas em métodos estatísticos. Este é o caso, por exemplo, do *classificador por distância mínima à média* (Lillesand & Kiefer, 1994). Neste caso, os pixels também são considerados como pontos em um espaço n -dimensional. Na fase de treinamento, as regiões selecionadas são usadas para definir agrupamentos de pontos neste espaço. São calculados então os centros de massa destes agrupamentos, que são dados pela média aritmética das coordenadas dos pontos contidos em cada um deles. A partir daí, cada pixel da imagem será agregado à classe representada pelo agrupamento cujo centro de massa esteja mais próximo segundo alguma métrica estabelecida.

5.3.2. Classificação Não-supervisionada

Na classificação não-supervisionada, o processo se dá, inicialmente, sem interferência humana, ou seja, não há fase de treinamento ou a necessidade de obter um conjunto de protótipos. Operações numéricas são utilizadas para detectar automaticamente os agrupamentos no espaço n -dimensional (*clustering*) (Jain, 1989). As n coordenadas do espaço euclidiano em questão, podem representar n

⁷ Em inglês: *Maximum Likelihood* ou *ML Classifier*.

diferentes propriedades dos pixels (ou grupo de pixels) da imagem, como por exemplo, a resposta espectral em diferentes bandas.

Uma vez detectados o agrupamentos (*clusters*) que representam as classes, cada pixel será classificado de acordo com algum critério de similaridade, que pode, inclusive, ser semelhante aos utilizados na classificação supervisionada.

5.4. ANÁLISE DE IMAGENS COM O SPRING

Algumas das ferramentas de auxílio a análise de imagens do SPRING foram citadas no capítulo anterior, como os filtros de detecção de bordas e os filtros morfológicos. Nesta seção, falamos sobre segmentação e classificação. Esta segunda é a mais importante das técnicas de análise, no contexto de imagens de sensoriamento remoto.

5.4.1. Segmentação de Imagens no SPRING

O SPRING possui dois métodos de segmentação de imagens: crescimento de regiões e detecção de bacias.

A primeira é baseada na estratégia que descrevemos na Seção 5.2. Inicialmente cada pixel é rotulado como uma região distinta. Calcula-se então uma medida de similaridade para cada par de regiões A e B , espacialmente adjacentes, as quais são agregadas desde que obedeçam aos seguintes critérios:

1. o grau de similaridade entre A e B satisfaz a um limiar preestabelecido;
2. A e B são as mais similares entre si, ou seja, dentre todas as regiões adjacentes a A , B é a mais similar e vice versa.

A medida de similaridade adotada é baseada na diferença entre as médias de níveis de cinza das regiões. Além dos critérios citados acima, pode-se também utilizar, alternativamente, um critério de área mínima das regiões, para evitar que surja um grande número de pequenas regiões. Caso este critério seja adotado, o critério 1, acima, só será considerado quando o tamanho da região for superior ao mínimo estabelecido.

O outro método disponível no SPRING é o de *detecção de bacias*. Neste caso, o algoritmo de segmentação se baseia em uma imagem gradiente, portanto necessita de um pré-processamento da imagem utilizando um filtro de Sobel ou Roberts.

O algoritmo pressupõe uma representação topográfica para a imagem, ou seja, cada nível de cinza na imagem de intensidade de gradiente equivale a um valor de elevação no respectivo ponto. A imagem seria equivalente a uma superfície topográfica com feições de relevo ou uma região com bacias de diferentes profundidades que são limitadas pelas bordas da imagem. O método baseia-se então em um crescimento de regiões que inicia pelos pixels com níveis de cinza mais baixos e que vai progressivamente ocupando níveis de cinza maiores, até que se atinja um limiar preestabelecido. A grosso modo, este procedimento é equivalente à imersão de uma superfície topológica em um lago, causando a inundação das diferentes bacias. Uma vez que se tenha alcançado o limite máximo de "inundação", são definidas barreiras entre as bacias para delimitar as diferentes regiões.

5.4.2. Classificação de Imagens no SPRING

As técnicas de classificação de imagens do SPRING estão divididas em dois tipos: *por pixel* e *por região*.

5.4.2.1. Classificação por Pixel

Nesta categoria estão algumas técnicas de classificação supervisionada, que são indicadas para situações em que o usuário dispõe de informações que permitem a identificação de classes de interesse.

Para o treinamento, o usuário deve identificar, na imagem, áreas representativas de cada classe. É importante que a área de treinamento seja uma amostra homogênea da respectiva classe, mas, ao mesmo tempo, deve-se incluir toda a variação de níveis de cinza que a classe possa conter. Para possibilitar a diminuição da confusão entre classes, o SPRING fornece algumas medidas estatísticas a respeito da classificação das amostras. Se a porcentagem de pixels de uma amostra, classificados erroneamente, for muito alta, isto significa que esta amostra foi mal escolhida e deve ser substituída. Todas as amostras devem ter aproximadamente 100% de seus pixels classificados na classe que representam.

O SPRING oferece duas variações de classificadores por pixel: MAXVER e distância euclidiana.

O algoritmo MAXVER disponível é como o descrito na Seção 5.3.1. Entretanto, pode ser definido também um limiar de aceitação, que indica a porcentagem de pontos que poderão ser classificados como pertencendo a uma determinada classe. Um limite de 99%, por exemplo, indica os 1% de pontos com menor probabilidade serão ignorados na classificação, considerando a hipótese de alguns pixels terem sido incluídos por engano durante o treinamento. Se o limiar for de 100%, todos os pixels da imagem serão incluídos em alguma classe.

Existe também a opção MAXVER-ICM (*Iterated Conditional Modes*), que considera também a dependência espacial na classificação. Neste método, leva-se em conta, também, a informação contextual da imagem. Após a classificação pelo MAXVER, uma certa porcentagem de pixels é reclassificada, com base em sua vizinhança. A porcentagem de pixels a serem reclassificados é estabelecida pelo usuário. Esta técnica pode evitar, por exemplo, que surjam pequenos agrupamentos de pixels que sejam classificados em classes distintas de suas vizinhanças. Estes agrupamentos podem deixar a imagem excessivamente detalhada ou ruidosa, o que dificulta sua análise.

Como classificação por pixel, esta disponível também o classificador *por distância euclidiana*. Este algoritmo é baseado na idéia de classificação por distância mínima à média, que citamos na Seção 5.3.1. A medida de distância que é utilizada neste caso é a euclidiana, que é definida para dois pontos $\mathbf{x} = (x_1, \dots, x_n)$ e $\mathbf{y} = (y_1, \dots, y_n)$ de um espaço n -dimensional como:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2}.$$

5.4.2.2. Classificação por Região

Na classificação por região o treinamento é não supervisionado. Isto significa que não é necessário que o usuário forneça amostras para identificar as classes. Ao invés disto, o classificador utiliza um método que identifica agrupamentos de pontos, baseando-se em um conjunto de regiões que são caracterizadas por atributos estatísticos.

Para a determinação dos agrupamentos, é feita inicialmente a segmentação da imagem. Em seguida as regiões da imagem segmentada vão sendo divididas em classes, baseando-se em um critério de similaridade. O método é dividido em três etapas:

1. **Definição do limiar:** o usuário define um limiar de aceitação dado em porcentagem. A partir deste limiar é definida a similaridade mínima para que uma região possa ser considerada como pertencente a uma classe. Quanto menor for este limiar, maior será o número de classes.
2. **Deteção de classes:** as regiões da imagem segmentada são ordenadas em ordem decrescente de área e inicia-se o processo para agrupá-las em classes. Seleciona-se a maior região que ainda não pertença a nenhuma classe; cria-se uma nova classe baseada nesta região; em seguida associa-se a esta classe todas as regiões cuja similaridade seja superior à distância definida pelo limiar de aceitação.
3. **Competição entre classes:** Os parâmetros estatísticos das classes são recalculados, levando-se conta, agora, as demais regiões que foram incluídas em cada uma das classes. Em seguida todas as regiões são reclassificadas baseando-se nos novos parâmetros. Este procedimento se repete até que haja convergência, isto é, até que os parâmetros estatísticos das classes não mais se alterem.

A competição entre classes visa eliminar um possível favorecimento que pode ocorrer em relação as classes que foram detectadas em primeiro lugar. Ao término do processo, todas as regiões estarão associadas a alguma das classes (ou temas) as quais poderão posteriormente ser discriminadas pelo usuário através de rótulos.

5.4.2.3. Pós-Classificação

Uma vez concluída a classificação, seja ela por pixel ou regiões, o SPRING oferece um procedimento opcional de pós-classificação. Este procedimento destina-se a eliminar pontos isolados classificados diferentemente de sua vizinhança, gerando assim uma imagem menos ruidosa. Para isto, utiliza-se uma janela de 3x3 pixels que percorre toda a imagem classificada substituindo ou não a classe de seu ponto central pela classe mais freqüente em sua vizinhança. A decisão sobre quando a classe do ponto central deve ser substituída ou não baseia-se nos valores de peso e limiar definidos pelo usuário.

O *peso* determina o número de vezes que será considerada a freqüência do ponto central, e o *limiar* é o valor de freqüência acima da qual o ponto central é modificado.

Supondo-se que o ponto central pertença a uma classe i , a decisão sobre mudança ou não de classe é feita da seguinte maneira: obtém-se a freqüência da classe i , que é dada pela soma do peso do ponto central ao número de demais ocorrências da classe i na janela; encontra-se a classe j com o maior número de ocorrências na

janela; por fim, a classe do ponto central será mudada de i para j se, e somente se, as seguintes condições forem satisfeitas:

1. a frequência de j é maior que a frequência de i .
2. a frequência de j é maior que o limiar estabelecido;

As definições do peso e do limiar dependerão dos objetivos a serem atingidos e das características da imagem classificada. Quanto menor forem o peso e o limiar, maior será o número de substituições e, conseqüentemente, mais suavizada será a imagem resultante.

6. REFERÊNCIAS BIBLIOGRÁFICAS

BALLARD, D.H.; BROWN, C.M. *Computer vision*. Englewood Cliffs: Prentice-Hall, 1982.

BRICE, C.R.; FENNEMA, C.L. Scene analysis using regions. In: AGGARWAL, J.K.; ROSENFELD, A., ed. *Computer Methods in Image Analysis*. Los Angeles: IEEE Computer Society. 1977.

CASTLEMAN, K.R. *Digital image processing*. Englewood Cliffs: Prentice-Hall, 1979.

CEDERBERG, R. Chain-link coding and segmentation for raster scan devices. *Computer Graphics and Image Processing*, v.10, p.224-234, 1979.

ELIASON, E.M.; McEWEN, A.S. Adaptive box filters for removal of random noise from digital images. *Photogrammetric Engineering & Remote Sensing*, v.56, n.4, p.453-458, 1990.

FROST, V.S.; STILES, J.A.; SHANMUGAN, K.S.; HOLTZMAN, J.C. A model for radar images and its applications to adaptive digital filtering of multiplicative noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI*, v.4, p.157-166, 1982.

GOMES, J.M.; VELHO, L. *Computação gráfica: Imagem*. Rio de Janeiro, RJ: IMPA/SBM, 1994.

GONZALEZ, R.C.; WOODS, R.E. *Digital image processing*. Reading: Addison-Wesley, 1992.

HARALICK, R.M. Statistical and structural approaches to texture. *IEEE Proceedings*, v.67, p.786-809, May, 1979.

JAIN, A.K. *Fundamentals of digital image processing*. Englewood Cliffs: Prentice-Hall, 1989.

JENSEN, J.R. *Introductory digital image processing: a remote sensing perspective*. 2.ed. Upper Saddle River: Prentice Hall, 1996.

KUAN, D.T.; SAWCHUK, A.A.; STRAND, T.C.; CHAVEL, P. Adaptive restoration of images with speckle. *SPIE Proceedings*, v.359, p.28-38, 1982.

LEE, J.S. Speckle analysis and smoothing of synthetic aperture radar images. *Computer Graphics and Image Processing*, v.17, p.24-32, 1981.

LEE, J.S. Digital image smoothing and the sigma filter. *Computer Vision, Graphics and Image Processing*, v.24, p.255-269, 1983.

LILLESAND, T.M.; KIEFER, R.W. *Remote sensing and image interpretation*. 3.ed. New York: John Wiley, 1994.

MARTELLI, A. Edge detection using heuristic search methods. *Computer Graphics and Image Processing*, v.1, p.169-182, Aug.; 1972.

NOVO, E.M.L.M. *Sensoriamento remoto: princípios e aplicações*. 2.ed. São Paulo: Editora Edgard Blücher, 1995.

PRATT, W.K. *Digital image processing*. 2.ed. New York: John Wiley, 1991.

SERRA, J. *Image analysis and mathematical morphology*. New York: Academic Press, 1982.

SPRING. Disponível: site SPRING home page (1996). URL: <http://www.inpe.br/spring/>. Consultado em 30 jun. 1997.



Empresa Brasileira de Pesquisa Agropecuária
Centro Nacional de Pesquisa Tecnológica em Informática para a Agricultura
Ministério da Agricultura e do Abastecimento
Av. Dr. André Tosello s/nº. - Cidade Universitária "Zeferino Vaz"
Barão Geraldo - Caixa Postal 6041
13083-970 - Campinas, SP
Telefone (019) 289-9800 - Fax (019) 289-9495
cnptia@cnptia.embrapa.br



- BIBLIOTECA -

